STRATEŠKI ZNAČAJ INFORMACIJSKIH TEHNOLOGIJA U UNAPREĐENJU KONKURENTSKE SPOSOBNOSTI PODUZEĆA

Badurina, Edvard

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Economics in Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:145:904805

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**



Repository / Repozitorij:

EFOS REPOSITORY - Repository of the Faculty of Economics in Osijek





Sveučilište Josipa Jurja Strossmayera u Osijeku

Ekonomski fakultet u Osijeku

Poslijediplomski doktorski studij „Management“

Edvard Badurina

STRATEŠKI ZNAČAJ INFORMACIJSKIH TEHNOLOGIJA U UNAPREĐENJU KONKURENTSKE SPOSOBNOSTI PODUZEĆA

Osijek, 2022.

Sveučilište Josipa Jurja Strossmayera u Osijeku

Ekonomski fakultet u Osijeku

Poslijediplomski doktorski studij „Management“

Edvard Badurina

STRATEŠKI ZNAČAJ INFORMACIJSKIH TEHNOLOGIJA U UNAPREĐENJU KONKURENTSKE SPOSOBNOSTI PODUZEĆA

DOKTORSKA DISERTACIJA

Mentor: prof. dr. sc. Jerko Glavaš

Osijek, 2022.

University Josip Juraj Strossmayer in Osijek

Faculty of Economics in Osijek

Postgraduate doctoral Study „Management“

Edvard Badurina

STRATEGIC IMPORTANCE OF INFORMATION TECHNOLOGISTS IN IMPROVING THE COMPETITIVENESS OF ENTERPRISES

DOCTORAL THESIS

Mentor: Professor Jerko Glavaš, Ph.D.

Osijek, 2022.

IZJAVA

O AKADEMSKOJ ČESTITOSTI, PRAVU PRIJENOSA INTELEKTUALNOG VLASNIŠTVA, SUGLASNOSTI ZA OBJAVU U INSTITUCIJSKIM REPOZITORIJIMA I ISTOVJETNOSTI DIGITALNE I TISKANE VERZIJE RADA

1. Kojom izjavljujem i svojim potpisom potvrđujem da je doktorski rad isključivo rezultat osobnoga rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu. Potvrđujem poštivanje nepovredivosti autorstva te točno citiranje radova drugih autora i referiranje na njih.
2. Kojom izjavljujem da je Ekonomski fakultet u Osijeku, bez naknade u vremenski i teritorijalno neograničenom opsegu, nositelj svih prava intelektualnoga vlasništva u odnosu na navedeni rad pod licencom *Creative Commons Imenovanje – Nekomercijalno – Dijeli pod istim uvjetima 3.0 Hrvatska.*
3. Kojom izjavljujem da sam suglasan/suglasna da se trajno pohrani i objavi moj rad u institucijskom digitalnom repozitoriju Ekonomskoga fakulteta u Osijeku, repozitoriju Sveučilišta Josipa Jurja Strossmayera u Osijeku te javno dostupnom repozitoriju Nacionalne i sveučilišne knjižnice u Zagrebu (u skladu s odredbama Zakona o znanstvenoj djelatnosti i visokom obrazovanju, NN br. 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15).
4. Izjavljujem da sam autor predanog rada i da je sadržaj predane elektroničke datoteke u potpunosti istovjetan sa dovršenom tiskanom verzijom rada predanom u svrhu obrane istog.

Ime i prezime studenta: Edvard Badurina

JMBG: 1809972361418

OIB: 20900848555

e-mail za kontakt: edvard.badurina@gmail.com

Naziv studija: Poslijediplomski doktorski studij „Management“

Naslov rada: Strateški značaj informacijskih tehnologija u unapređenju konkurentske sposobnosti poduzeća

Mentor rada: prof.dr.sc. Jerko Glavaš

U Osijeku, 30.10. 2022. godine

Potpis Badurina

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku **Doktorska disertacija**
Ekonomski fakultet u Osijeku
Poslijediplomski doktorski studij Management

Znanstveno područje: društvene znanosti
Znanstveno polje: ekonomija

STRATEŠKI ZNAČAJ INFORMACIJSKIH TEHNOLOGIJA U UNAPREĐENJU KONKURENTSKE SPOSOBNOSTI PODUZEĆA

Edvard Badurina

Disertacija je izrađena u: Rijeci

Mentor: prof.dr.sc. Jerko Glavaš

Komentor: doc.dr.sc. Andreja Rudančić

Kratki sažetak doktorske disertacije:

Intencija je ovog doktorskog rada da se problematika korištenja informacijsko-komunikacijske tehnologije u hotelskoj industriji obrazloži na sustavan način i argumentirano ukaže na sve prednosti koje informacijska i računalna tehnologija pruža u suvremenom hotelijerskom poslovanju. Osnovu svega čini poznavanje informacijskog sustava, njegove funkcije i mogućnosti te zavisnosti o informatičkoj infrastrukturi, koja zbog razvijenosti i konfiguracije Republike Hrvatske nije jednako dostupna svim hotelskim subjektima. Druga važna tema koja se proteže kroz istraživanje strateško je promišljanje o korištenju novih tehnologija. Suvremeno hotelsko poslovanje ne dopušta raspravu o tome hoće li se IT koristiti, već kako ga iskoristiti za ostvarenje postavljenih strateških ciljeva i održavanje konkurentnosti na turističkom tržištu. U tom kontekstu dolazi do izražaja važnost menadžerskog odlučivanja, koje na raspolaganju ima poslovni informatički sustav, sustave podrške odlučivanju i poslovnu inteligenciju kao sredstva i alate za kreiranje odluka i vođenje. Treća je tema upravljanje odnosima s gostom, koja subjekte hotel i gost promatra kao ravnopravne partnere s mnogo zajedničkih dodirnih točaka. Sustav upravljanja odnosima s gostom, iako prvotno osmišljen kao jednosmjeran marketinški alat orijentiran na gosta kao objekt ostvarenja dobiti, sve više postaje interakcijski mehanizam u kojem gost dolazi u ravnopravni, ako ne i dominantni položaj. To mu omogućuju brojni komunikacijski kanali na društvenim medijima, što je pak poticaj hotelskom menadžmentu da pored permanentnog rada na unaprjeđenju kvalitete usluge, posredstvom informacijske i računalne tehnologije, unaprjeđuje i odnose s gostom.

Broj stranica: 265

Broj slika: 32

Broj tablica: 106

Broj literaturnih navoda: 125

Jezik izvornika: hrvatski jezik

Ključne riječi: informacijska tehnologija, strateški menadžment, poslovna inteligencija, upravljanje odnosima s gostima

Datum obrane: 21.10.2022.

Stručno povjerenstvo za obranu:

1. Predsjednik: Prof.dr.sc. Branimir Dukić
2. Član: Prof.dr.sc. Mislav Šimunić
3. Član: doc dr.sc. Damir Šebo

Disertacija je pohranjena u: Nacionalnoj i sveučilišnoj knjižnici Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; Gradskoj i sveučilišnoj knjižnici Osijek, Europska avenija 24, Osijek; Sveučilištu Josipa Jurja Strossmayera u Osijeku, Trg sv. Trojstva 3, Osijek; Ekonomskom fakultetu u Osijeku, Trg Lj. Gaja 7, Osijek.

BASIC DOCUMENTATION CARD

Josip Juraj Strossmayer University of Osijek **PhD thesis**
Faculty of Economics in Osijek
University Doctoral Study of Management

Scientific Area: social sciences
Scientific Field: economics

STRATEGIC IMPORTANCE OF INFORMATION TECHNOLOGISTS IN IMPROVING THE COMPETITIVENESS OF ENTERPRISES

Edvard Badurina

Thesis performed at: Rijeka

Mentor: Associate Professor Jerko Glavaš, Ph.D.

Supervisor: Assistant Professor Andreja Rudančić, Ph.D.

Short abstract:

The intention of this doctoral dissertation is to explain the problems of using information and communication technology in the hotel industry in a systematic way and to point out all the advantages that information and computer technology provides in the modern hotel business. The basis of all is knowledge of the information system, its function and capabilities, and dependence on the IT infrastructure, which, due to the development and configuration of the Republic of Croatia, is not uniformly accessible to all hotel entities. Another important topic, which extends through research, is strategic thinking about the use of new technologies. Modern hotel business does not allow discussing whether IT will be used, but how to use it to achieve the set strategic goals and maintain competitiveness in the tourism market. In this context, the importance of managerial decision-making, which has a business information system, decision support systems and business intelligence as tools and tools for decision-making and leadership, is emphasized. The third theme is customer relationship management, which views hotel and guest entities as equal partners with many common touch points. Although originally designed as a one-way guest-oriented marketing tool as an object of profit, the customer relationship management system is increasingly becoming an interaction mechanism in which the guest comes to an equal if not dominant position. This is enabled by numerous communication channels on social media, which in turn is an incentive for the hotel management to improve

relations with the guest through information and computer technology in addition to continuous work on improving the quality of service.

Number of pages: 265

Number of figures: 32

Number of tables: 106

Number of references: 125

Original in: Croatian language

Key words: information technology, strategic management, business intelligence, customer relations management

Date of the thesis defense:

Reviewers:
1.
2.
3.

Thesis deposited in: National and University Library in Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; City and University Library of Osijek, Europska avenija 24, Osijek; Josip Juraj Strossmayer University of Osijek, Trg sv. Trojstva 3, Osijek; Faculty of Economics in Osijek, Trg Lj. Gaja 7, Osijek.

ZAHVALA

Posebnu zahvalu upućujem mentoru, prof.dr.sc. Jerku Glavašu na stručnom vođenju i usmjeravanju tijekom studija te pomoći oko provedbe istraživanja i izradi doktorske disertacije.

Zahvalu upućujem i komentorici doc.dr.sc. Andreji Rudančić na danim brojnim, profesionalnim i prijateljskim savjetima, na nesebičnoj i neizmjernoj pomoći u izradi ove doktorske disertacije.

Zahvaljujem posebno i svojoj obitelji, supruzi Tei, kćerkama Korini i Luni, bez cijeg razumijevanja nikada ne bih mogao odvojiti neophodno potrebno vrijeme za istraživački rad i pisanje disertacije.

SAŽETAK

STRATEŠKI ZNAČAJ INFORMACIJSKIH TEHNOLOGIJA U UNAPREĐENJU KONKURENTSKE SPOSOBNOSTI PODUZEĆA

Intencija je ovog doktorskog rada da se problematika korištenja informacijsko-komunikacijske tehnologije u hotelskoj industriji obrazloži na sustavan način i argumentirano ukaže na sve prednosti koje informacijska i računalna tehnologija pruža u suvremenom hotelijerskom poslovanju. Osnovu svega čini poznavanje informacijskog sustava, njegove funkcije i mogućnosti te zavisnosti o informatičkoj infrastrukturi, koja zbog razvijenosti i konfiguracije Republike Hrvatske nije jednako dostupna svim hotelskim subjektima. Druga važna tema koja se proteže kroz istraživanje strateško je promišljanje o korištenju novih tehnologija. Suvremeno hotelsko poslovanje ne dopušta raspravu o tome hoće li se IT koristiti, već kako ga iskoristiti za ostvarenje postavljenih strateških ciljeva i održavanje konkurentnosti na turističkom tržištu. U tom kontekstu dolazi do izražaja važnost menadžerskog odlučivanja, koje na raspolaganju ima poslovni informatički sustav, sustave podrške odlučivanju i poslovnu inteligenciju kao sredstva i alate za kreiranje odluka i vođenje. Treća je tema upravljanje odnosima s gostom, koja subjekte hotel i gost promatra kao ravnopravne partnere s mnogo zajedničkih dodirnih točaka. Sustav upravljanja odnosima s gostom, iako prvotno osmišljen kao jednosmjeran marketinški alat orijentiran na gosta kao objekt ostvarenja dobiti, sve više postaje interakcijski mehanizam u kojem gost dolazi u ravnopravni, ako ne i dominantni položaj. To mu omogućuju brojni komunikacijski kanali na društvenim medijima, što je pak poticaj hotelskom menadžmentu da pored permanentnog rada na unaprjeđenju kvalitete usluge, posredstvom informacijske i računalne tehnologije, unaprjeđuje i odnose s gostom.

Ključne riječi: informacijska tehnologija, strateški menadžment, poslovna inteligencija, upravljanje odnosima s gostima

SUMMARY

STRATEGIC IMPORTANCE OF INFORMATION TECHNOLOGISTS IN IMPROVING THE COMPETITIVENESS OF ENTERPRISES

The intention of this doctoral dissertation is to explain the problems of using information and communication technology in the hotel industry in a systematic way and to point out all the advantages that information and computer technology provides in the modern hotel business. The basis of all is knowledge of the information system, its function and capabilities, and dependence on the IT infrastructure, which, due to the development and configuration of the Republic of Croatia, is not uniformly accessible to all hotel entities. Another important topic, which extends through research, is strategic thinking about the use of new technologies. Modern hotel business does not allow discussing whether IT will be used, but how to use it to achieve the set strategic goals and maintain competitiveness in the tourism market. In this context, the importance of managerial decision-making, which has a business information system, decision support systems and business intelligence as tools and tools for decision-making and leadership, is emphasized. The third theme is customer relationship management, which views hotel and guest entities as equal partners with many common touch points. Although originally designed as a one-way guest-oriented marketing tool as an object of profit, the customer relationship management system is increasingly becoming an interaction mechanism in which the guest comes to an equal if not dominant position. This is enabled by numerous communication channels on social media, which in turn is an incentive for the hotel management to improve relations with the guest through information and computer technology in addition to continuous work on improving the quality of service.

Keywords: information technology, strategic management, business intelligence, customer relations management

PREDGOVOR

Ovaj je rad dovršavan u razdoblju pandemije virusa COVID-19, koji je pokazao svu krhkost suvremenog poimanja življenja, dostignutu slobodu kretanja, želje za zasluženim odmorom u poznatoj destinaciji, boravka u omiljenom hotelu i večere u restoranu u okruženju dragih nam osoba. *Eppur si muove* i turistički šou krenut će iznova, ako ni zbog čega onda zbog ljudske iskonske težnje za kretanjem i istraživanjem novih područja zanimanja. Ono što je pozitivno, i što se je pokazalo ključnim u vremenima izolacije, jest rezistentnost informacijsko-komunikacijske tehnologije na ljudske nedaće. Brzina i višekanalnost prijenosa informacija pokazala se ključnom, a informacijska se tehnologija našla u fokusu cijele svjetske javnosti i od alata i sredstva postala subjekt upravljanja načinom života.

Ovakva digresija na moć koju ima informacijska tehnologija usmjerena je na temu istraživanja doktorskog rada, koja većinom obrazlaže učinak informacijske i informacijske (računalne) tehnologije na poslovne sustave, s naglaskom na upravljanje odnosima s korisnicima. Informacijsko-komunikacijska tehnologija u tome ima ulogu sredstva interakcije između proizvođača usluge (hotelskog poduzeća) i korisnika ili potencijalnog korisnika usluge (gosta). Ako se pritom koristi, a koristi se, informacijska tehnologija tada ulogu moderatora interakcije hotel-gost preuzima računalo, koje pomoću poslovne inteligencije upravlja odnosima s gostima, s ciljevima povećanja dobiti i povećanja zadovoljstva gosta.

POPIS KORIŠTENIH POJMOVA I KRATICA

S obzirom na to da se u radu koristi dio uvriježene informacijske terminologije koja se služi pokratama, odnosno akronimima engleskih naziva, potrebno je istaknuti najčešće korištene pokrate i njihova pojašnjenja.

POKRATA	IZVORNO	HRVATSKI
CH	Churn	Potencijalni prebjeg (gost koji nije lojalan)
BD	Big Data	Velika podatkovna baza
BPR	Business Process Reengineering	Reinženjering poslovnog procesa
BI	Business Intelligence	Poslovna inteligencija
CRM	Customer Relationship Management	Upravljanje odnosima s klijentima
CT	Computer technology	Računalna tehnologija
DSS	Decision Support Systems	Sustav podrške odlučivanju
ICT	Information and communication technologies	Informacijsko-komunikacijska tehnologija
IT	Information Technology	Informacijska tehnologija
IT*	Information Technology	Informatička tehnologija
MIS	Management Information System	Menadžerski informacijski sustav
SCRM	Social Customer Relationship Management	Društveni mediji i upravljanje odnosima s klijentima

Uvodno je potrebno pojasniti sinonime koji se učestalo pojavljuju u radu, a odnose se na izvorni pojam na engleskom *Information Technology*. U hrvatskom se jeziku koriste pojmovi informacijska tehnologija i informatička tehnologija, koji su istoznačni, ali se koriste zavisno o kontekstu je li riječ o prijenosu podataka bez ili uz korištenje računalne tehnologije.

SADRŽAJ

PREDGOVOR

SAŽETAK

SUMMARY

POPIS KORIŠTENIH KRATICA

1. UVOD 1
1.1 Predmet istraživanja 2
1.2 Svrha, ciljevi i hipoteze istraživanja 3
1.3 Ocjena i prikaz dosadašnjih istraživanja 6
1.4 Znanstvene metode istraživanja 10
1.5 Kompozicija doktorske disertacije 11
2. INFORMACIJSKI SUSTAV KAO RESURSNA OSNOVA POSLOVANJA PODUZEĆA 15
2.1 Teorijske determinante informacijskog sustava 15
2.1.1 Pojam i definicije poslovno-informacijskog sustava (PIS-a) 17
2.1.2 Dijelovi informacijskoga sustava 18
2.2 Integralni informacijski poslovni sustav 20
2.3 Utjecaj informacijskog poslovnog sustava na konkurentnost poslovanja poduzeća . 22
2.3.1 Strateška važnost primjene IT-ja 23
2.3.2 Određivanje uloge informatike u poslovanju 24
2.3.3 Vrednovanje IT-ja u poslovanju 26
2.4 Utjecaj razvoja informacijske tehnologije na hotelsku industriju 28
3. STRATEŠKI MENADŽMENT HOTELSKOG PODUZEĆA KAO POLUGA IZVRSNOSTI POSLOVANJA 30
3.1 Važnija obilježja hotelskog poduzeća kao poslovnog sustava 30
3.1.1 Okolina hotelskog poduzeća 31
3.1.2 Organizacijska struktura hotelskog poduzeća 32
3.1.3 Organizacija poslovnih i procesnih funkcija u hotelskom poduzeću 33
3.2 Razine i funkcije menadžmenta u hotelskom poduzeću 34
3.2.1 Zahtjevi i ciljevi pred menedžmentom u hotelu 34
3.2.2 Menadžerski podsustavi 36
3.3 Strateški menadžment u hotelskom poduzeću 39
3.3.1 Posebnosti strateškog menadžmenta u hotelijerstvu 39
3.3.2 Moguće strategije hotelskih poduzeća 42
3.3.3 Modeli strateškog menadžmenta u hotelskoj industriji 44
3.3.4 Generičke strategije 46
3.3.5 Proces strateškog menadžmenta 47
4. KRUCIJALNOST PRIMJENE INFORMACIJSKIH TEHNOLOGIJA KAO FAKTOR USPJEŠNOM MENADŽERSKOM ODLUČIVANJU U HOTELSKOM PODUZEĆU 49
4.1 Menadžerske odluke i sustavi odlučivanja u hotelskom poduzeću 49
4.1.1 Vrste odluka i modeli odlučivanja 50
4.1.2 Poslovno i menadžersko odlučivanje 51
4.1.3 Sustavi za podršku u menadžerskom odlučivanju 53
4.1.4 Metode potpore odlučivanju 55
4.1.5 Sustav potpore odlučivanja u skupini – GDSS 57

4.1.6 Sustavi podrške odlučivanju (DSS) ... 58
4.1.7 Sustavi podrške grupnom odlučivanju (GDSS) ... 61
4.2 Menadžerski informacijski sustavi – MIS ... 62
4.2.1 Razine menadžerskog informacijskog sustava ... 64
4.2.2 Vrste poslovnih informacijskih sustava ... 70
4.3 Značajke informatizacije hotelskog poslovanja ... 72
5. POSLOVNA INTELIGENCIJA KAO NOVA PARADIGMA INOVIRANJA KONCEPCIJE RAZVOJA HOTELSKOG PODUZEĆA ... 75
5.1 Odrednice poslovne inteligencije ... 75
5.1.1 Značaj poslovne inteligencije u funkciji anticipiranja koncepcije razvoja hotelskog poduzeća ... 78
5.1.2 Poslovna inteligencija u sinergijskom efektu novih strateških usmjerenja hotelskog poduzeća ... 78
5.1.3 Pametni turizam ... 79
5.2 Prilagodba hotelskog poduzeća politici novih tržišnih vrijednosti ... 80
6. UPRAVLJANJE ODNOSIMA S GOSTIMA – FUNKCIJA INTEGRIRANOG INFORMACIJSKO-KOMUNIKACIJSKOG SUSTAVA HOTELSKOG PODUZEĆA ... 82
6.1 Općenito o upravljanju odnosima s gostima ... 82
6.1.1 Uloga informacijske tehnologije u upravljanju odnosima s kupcima ... 83
6.1.2 Internet u funkciji razvoja odnosa s klijentima u turizmu ... 83
6.2 Primjena e-marketinga u hotelijerstvu ... 84
6.2.1 Subjekti e-marketinga u hotelijerstvu i turizmu ... 85
6.2.2 Hotelske mrežne stranice ... 87
6.2.3 Mrežne stranice za mobilne uređaje ... 89
6.2.4 Izravni marketing ... 89
6.3 CRM u hotelskoj industriji ... 90
6.3.1 Proces upravljanja odnosima s gostima ... 92
6.3.2 Baze podataka osnova uspostave e-CRM-a ... 94
6.3.3 Big Data ... 95
6.3.4 Veza između tehnologije „Big Data“ i CRM-a ... 96
6.3.5 Komponente CRM-a ... 97
6.3.6 Alati CRM-a ... 100
6.3.7 Životni ciklus CRM-a ... 102
6.3.8 IT u funkciji primjene e-CRM modela u turizmu ... 103
6.3.9 E-zadovoljstvo klijenata u turizmu ... 105
6.3.10 E-odanost ... 106
6.3.11 CRM i angažman gosta ... 106
6.3.12 Prednosti i nedostaci uporabe CRM-a ... 107
6.4 Integrirani CRM i upravljanje prihodima ... 109
6.4.1 Mjera lojalnosti ... 109
6.5 Društvene mreže u funkciji upravljanja gostima u hotelskoj industriji ... 112
6.5.1 Uloga društvenih mreža u razvoju odnosa sa kupcima u turizmu ... 113
6.5.2 Tehnologija društvenih medija ... 114
6.5.3 Društveni mediji i angažman gosta ... 115
6.5.4 Angažman gosta i usmena predaja ... 116
6.5.5 Vjernost hotelskom brendu ... 117
6.5.6 Konceptualni model SCRM-a ... 118

7. EMPIRIJSKO ISTRAŽIVANJE OPERATIVNE EFIKASNOSTI I INOVATIVNOSTI PRIMJENE ICT TEHNOLOGIJE U POSLOVANJU HOTELSKIH PODUZEĆA U REPUBLICI HRVATSKOJ 120
7.1 Metodologija istraživanja 120
7.2 Opći podatci o uzorku ispitanika 121
7.2.1 Poslovna funkcija ispitanika 122
7.2.2 Dob ispitanika 122
7.2.3 Stupanj obrazovanja ispitanika 123
7.2.4 Radno iskustvo ispitanika 124
7.3 Opći podatci o objektima istraživanja 125
7.3.1 Distribucija uzorka hotela prema lokaciji 126
7.3.2 Veličina hotela 127
7.3.3 Vrsta hotela prema načinu poslovanja 128
7.3.4 Vrste hotela prema namjeni poslovanja 129
7.4 Ocjena elemenata integriranih informacijsko-komunikacijskih usluga – osnovne usluge 130
7.4.1 Telefonija i telefonske aplikacije 130
7.4.2 Integracija fiksne i mobilne telefonije na razini hotela 134
7.4.3 Hotelski sustav reklamiranja 138
7.4.4 Zabava za goste kad su u sobama 142
7.4.5 Pristup internetu 145
7.4.6 Kontrola ulaza 149
7.4.7 Kontrola i upravljanje minibarom 153
7.4.8 Upravljanje osvjetljenjem 156
7.4.9 Upravljanje energijom u hotelu 160
7.4.10 Upravljanje sigurnošću u hotelu 163
7.4.11 Korištenje pametnih kartica 167
7.4.12 Analiza osnovnih usluga integriranih informacijsko-komunikacijskih usluga 170
7.5 Ocjena elemenata integriranih informacijsko-komunikacijskih usluga – konferencijske usluge 175
7.5.1 IP telefonija 176
7.5.2 Videokonferencije 177
7.5.3 Analiza konferencijskih usluga integriranih informacijsko-komunikacijskih usluga u hotelu 179
7.6 Ocjena elemenata integriranih informacijsko-komunikacijskih usluga – interno oglašavanje 182
7.6.1 Plazma ekrani 183
7.6.2 Infokiosci 184
7.6.3 Ekrani na VoIP telefonima u sobi 186
7.6.4 IP televizije u sobama 187
7.6.5 Interne mrežne stranice i mrežni portali za goste 189
7.6.6 Analiza internog oglašavanja u sklopu integriranih informacijsko-komunikacijskih usluga 191
7.7 Ocjena elemenata integriranih informacijsko-komunikacijskih usluga – ostale usluge 197
7.7.1 Interaktivne informacije o događanjima u destinaciji 197
7.7.2 Interaktivna rezervacija restorana 199
7.7.3 Interaktivna rezervacija rekreativnih sadržaja 201
7.7.4 Analiza ostalih usluga u sklopu integriranih informacijsko-komunikacijskih usluga 202

7.8 Ocjene funkcija sustava CRM-a ... 208
7.8.1 Unaprjeđenje usmjerenosti gostiju prema potrošnji ... 208
7.8.2 Unaprjeđenje kvalitete pružene usluge ... 210
7.8.3 Unaprjeđenje lojalnosti gostiju ... 213
7.8.4 Unaprjeđenje konkurentnosti hotela ... 215
7.8.5 Upravljanje podatkovnom bazom gostiju ... 217
7.8.6 Analiza funkcija sustava CRM-a ... 219
7.9 Ocjene korisničke podrške sustava CRM-a ... 222
7.9.1 Upravljanje prodajnim procesom ... 222
7.9.2 Jedinstvena lista svih gostiju, dobavljača i partnera ... 224
7.9.3 Jedinstvena lista afiniteta gostiju ... 227
7.9.4 Upravljanje reklamacijama ... 229
7.9.5 Praćenje konkurencije ... 231
7.9.6 Integracija s elektroničkom poštom i potpora za mail merge ... 233
7.9.7 Analiza korisničke podrške CRM-a ... 234
7.10 Razvojni elementi CRM-a ... 237
7.11 Model razvoja primjene ICT-a u hotelskoj industriji ... 240
7.12 Zadovoljstvo postojećim sustavom ICT-a u hotelu ... 245
7.13 Percepcija značaja informatičkog sustava CRM-a ... 246
7.14 Budućnost CRM-a u hotelijerstvu ... 247
7.15 Stavovi poznavatelja o razvoju CRM-a ... 248
7.16 Rasprava ... 249
8. ZAKLJUČAK ... 251
POPIS LITERATURE ... 255
PRILOG – ANKETNI UPITNIK POPIS ILUSTRACIJA ... 263
POPIS SLIKA ... 263
POPIS GRAFIKONA ... 264
POPIS TABLICA ... 265

UVOD

Tehnologija i gospodarske aktivnosti spajaju ljude na razini komunikacije i poslovanja. Sposobnost izgrađivanja i uvažavanja novih tehnologija pokazuje zrelost društva i njegovu sklonost ka promjenama u skladu s novim načinima rada i života, kao i s novim povijesnim okruženjem i kretanjima. S druge strane, primjena raznih elemenata informacijske tehnologije postala je vrlo dinamična u svim područjima rada i života. Po mogućnostima koje pruža, informacijsku se tehnologiju može smatrati dijelom tehnološke evolucije. Pojam *informacijska tehnologija* može se koristiti u širokom značenju, a obuhvaća sva ona sredstva (alate i sustave) čija je glavna zadaća rad s informacijskim sadržajima.

Tehnološke inovacije otvaraju brojne mogućnosti za gospodarske djelatnosti i time potiču gospodarski rast. Zato gospodarstvo ulaže u razvoj novih tehnologija, a da pritom gospodarski ciljevi ujedno potiču razvoj novih tehnologija. Informacijska je tehnologija za poduzeća koja posluju, pa tako i hotelska poduzeća, alat koji omogućuje s jedne strane neometano odvijanje poslovnih procesa, a s druge strane realizira konkurentsku prednost. Brojne su djelatnosti u kojima je adekvatno korištenje informacijske tehnologije preduvjet opstanka na tržištu. Suvremene tehnologije nezaobilazno su sredstvo koje menadžeru pomaže u obradi informacije, s ciljem što veće učinkovitosti i kvalitete, pri čemu menadžer ne želi koristiti komparativne prednosti, nego želi biti nositelj istih, odnosno biti najbolji u odnosu na svoje konkurente.

Napredak tehnike i tehnologije, i to posebice u sferi informacijske tehnologije i komunikacija, izaziva značajne promjene, koje se trenutačno odvijaju na globalnim tržištima. Informacijski menadžment se tu ističe kao glavni trend uspješnog poslovanja, koji ima značajan utjecaj na ukupnu vrijednost kroz povezivanje, umrežavanje, obradu i pohranu informacija te distribuciju istih. U posljednjem desetljeću informacijska tehnologija je u potpunosti promijenila globalnu turističku industriju. Najveće promjene vidljive su u načinu komuniciranja između turističke industrije i korisnika njihovih usluga jer, slijedom navedenog, turističko je tržište 21. stoljeća određeno dinamikom i turbulencijom te mu je vrlo teško determinirati budući smjer, intenzitet i dinamiku aktivnosti. Jedino je sigurno da su promjene propulzivnije i konstanta, stoga menadžment hotelskog poduzeća mora biti orijentiran na novu kreaciju usluge koja će zadovoljiti gosta u svakoj prilici, odnosno kako multiplicirati dobit te ostvariti rast i razvoj hotelskog poduzeća u promjenjivoj okolini. Informacijske tehnologije predstavljaju temeljno sredstvo strategije svake organizacije, gdje su jedan od ključnih menadžerskih alata s obzirom na to da olakšavaju upravljanje njezinim resursima, povećavaju joj produktivnost te služe kao

oslonac u rješavanju strateških i operativnih pitanja što ih nameće suvremeno tržište. U toj sferi razmišljanja postepeno raste svijest menadžera o značenju i dometima informacijskih tehnologija, odnosno diversificiraju se različiti utjecaji informacijskih tehnologija na strateško odlučivanje i vođenje unutar hotelskog poduzeća.

1.1 Predmet istraživanja

Trend kretanja i razvoja novih proizvoda (usluga) temelji se na implementaciji informacijske tehnologije unutar strukture rada u hotelskom sustavu. Važno je istaći da se informacijska tehnologija sve više koristi za predviđanje budućnosti i anticipiranje budućih trendova na turističkom tržištu, što s jedne strane zahtijeva redefiniranje poslovanja, odnosno reinženjering poduzeća uz korištenje kvalitativnih alata istraživanja turističkog tržišta, poput *benchmarking* analize i SWOT matrice.

Važan segment koji se jednako tako pojavljuje u razvoju i napretku hotelskog poduzeća je i poslovna inteligencija, koja zauzima strateški značaj u konkurentskoj borbi na turističkom tržištu. Odnosno, poslovna inteligencija daje odgovor na aktivnosti konkurencije i nove poslovne kulture *Customer Relationship Managementa* (CRM) kao novi odnos s turistima, u ovom slučaju gostima hotela, a sve u svrhu generiranja novog, jedinstvenog doživljaja za turista kao pokretača promjena. Kako je u današnjem poslovanju vrlo važan gost i njegova interakcija s hotelskim poduzećem, ističe se važnost CRM-a s fokusom na klijenta. Temelj upravljanja odnosima s klijentom (gostom hotela), predstavlja poznavanje gosta, kako bi mu hotelsko poduzeće „isporučivalo“ veću vrijednost za novac.

CRM je na neki način metodologija hotelskog poduzeća koja se koristi kao nadogradnja orijentiranosti prema gostu (klijentu), odnosno to je proces koji stvara personalizirane trajne veze hotelskog poduzeća i gosta, a sve u svrhu povećanja njegovog zadovoljstva pruženom uslugom. U pravcu tog razmišljanja treba istaći da je CRM stvoren u vrijeme značajnog porasta zanimanja za neposredno kontaktiranje s gostom te uvođenja informacijske i komunikacijske tehnologije u poslovanje hotelskih poduzeća, a kao takav zauzima strateški značaj u poslovanju hotelskog poduzeća. CRM doživljava svoj razvoj uključivanjem društvenih odnosa s klijentima te postupno prelazi u SCRM odnosno CRM 2.0. Razvojem statističkih aplikacija CRM-u se otvara prostor upravljanja velikim bazama podataka (*Big Data*), što omogućuje interakciju s velikim brojem klijenata.

Tako definirana i obrazložena problematika istaknula je ***predmet istraživanja*** doktorskog rada: istražiti te znanstveno i argumentirano obrazložiti prednosti i moguće nedostatke korištenja suvremenih informacijskih tehnologija u hotelskom poslovanju. Kao poseban ***objekt istraživanja*** nalaze se odnosi s gostima, odnosno korisnicima hotelskih usluga.

1.2 Svrha, ciljevi i hipoteze istraživanja

Izravno i u najužoj vezi sa znanstvenim problemom, predmetom i objektom znanstvenog istraživanja te postavljenim radnim i pomoćnim hipotezama, određeni su svrha, ciljevi i zadatci istraživanja.

Svrha istraživanja je uporabom znanstveno-istraživačkih metoda doći do spoznaje o involviranosti uporabe informacijske tehnologije u poslovanju hotelskog poduzeća, vrjednovanje učinaka integriranih komunikacijskih usluga u hotelu, ocjenu prihvatljivosti CRM-a u hotelskom poslovanju te odgovarajućim modelom procijeniti razvojne mogućnosti korištenja CRM-a u perspektivi. Sukladno navedenom, osnovni je zadatak doktorske disertacije na temelju provedenog empirijskog istraživanja, statističke analize te dobivenih zaključaka donijeti argumentirane zaključke sukladno svrsi doktorske disertacije.

U svrhu dokazivanja postavljenih hipoteza u ovoj doktorskoj disertaciji postavljaju se sljedeći ***ciljevi istraživanja***:

- razmotriti temeljne odrednice informacijskog sustava kao resursne osnove poslovanja poduzeća
- pojmovno raščlaniti strateški menadžment hotelskog poduzeća kao poluga izvrsnosti poslovanja
- definirati eksternu i internu okolinu hotelskog poduzeća
- ukazati na značenje primjene informacijskih tehnologija u menadžerskom odlučivanju u hotelskom poduzeću
- identificirati uspostavljanje i efikasnost CRM modela u hotelska poduzeća
- istražiti operativnu efikasnost uporabe i primjene informacijske tehnologije na poslovanje hotelskih poduzeća u Republici Hrvatskoj
- odgovarajućim modelom procijeniti razvojne mogućnosti korištenja CRM-a kao razvojne i konkurentske perspektive.

Zadatci doktorske disertacije su:

- identificirati teoretsko-metodološku osnovu pojma, vrsta, i komponenata informacijske tehnologije
- temeljem teorijskih saznanja i parametara o razvoju informacijskog sustava, istražiti koncept životnog ciklusa informacijskog poslovnog sustava
- istražiti trendove, stanje, izazove i konkurentnost hrvatske hotelske industrije
- spoznati elemente menadžerskog informacijskog sustava te značajke informatizacije hotelskog poslovanja
- ukazati na značaj poslovne inteligencije koja je u funkciji anticipiranja koncepcije hotelskog poduzeća
- determinirati ulogu CRM-a kao koncept vrijednosti u implementiranju strateškog procesa hotelskog poduzeća
- ocijeniti stanje, prilike i perspektive operativne efikasnosti informacijske tehnologije u hrvatskim hotelskim poduzećima, vrednovati njihove učinke primjene i predložiti daljnje razvojne mogućnosti inoviranja koncepcije razvoja hotelskih poduzeća Republike Hrvatske.

Sukladno obrazloženom problemu i predmetu istraživanja, definiranoj svrsi, ciljevima i zadatcima koji se žele dostići, postavljaju se i određene hipoteze istraživanja.

U disertaciji su postavljene glavne hipoteze i tri pomoćne hipoteze koje će se dokazati ili odbaciti (djelomično odbaciti) adekvatnim znanstvenim metodama. Radi se o sljedećim hipotezama:

H 1: *Mjesto i uloga informacijske tehnologije u poslovnoj strategiji poduzeća određuje njezinu uspješnost i konkurentnost na tržištu. Stoga strategija razvoja informacijskog sustava i uvođenje novih informacijskih tehnologija u hotelsko poslovanje postaje bitan, sastavni dio poslovne koncepcije i strategije svakog poduzeća.*

Tako postavljena glavna hipoteza istraživanja implicira postavljanje i odgovarajućih pomoćnih hipoteza:

PH 1 Strateški pristup menadžmentu u hotelskoj industriji ključan je za dugoročno planiranje koje uključuje prihvaćanje inovativnih procesa iz sektora ITC-a.

PH 2 Implementacijom informacijske tehnologije u poslovanje hotelskih poduzeća povećava se efikasnost poslovanja u sferi smanjenja troškova rada, potrebne radne snage i skraćuje potrebno vrijeme reagiranja i izvršenja poslovnih zadataka.

PH 3 *Customer Relationship Management* (CRM) kao nova poslovna kultura s fokusom na klijenta (gosta) ima za cilj povećati kvalitativne pomake poslovanja hotelskog poduzeća na način da izgrađuje odnos s postojećim gostima putem mjerenja i vrjednovanja njihove razine očekivanja i zadovoljstva pruženom uslugom.

Sustavnim i analitičkim pristupom proučavanja odnosa u suvremenom upravljanju hotelima, uvažavajući najbolju praksu i dostignute rezultate relevantnih hotelskih tvrtki, pokušat će se dokazati postavljene tvrdnje.

Glavna hipoteza rada korelira s rezultatima poslovanja suvremenih hotelskih kuća, što samo naizgled pojednostavnjuje dokazivanje s obzirom na to da u svijetu postoje brojni primjeri uspješnog poslovanja klasičnim načinima upravljanja hotelima. Naime, sve prednosti koje nude suvremene tehnologije ne mogu nadomjestiti temeljnu zadaću pružanja kvalitetne usluge prehrane i smještaja gostiju. Stoga nije namjera ovog istraživanja tražiti dokaze kako su informacijske tehnologije zaslužne za uspješnost poslovanja hotelskog poduzeća, već je namjera dokazati kako se pravilnim korištenjem informacijskih tehnologija kao alata pomoću kojih je moguće unaprijediti odnose s klijentima.

U tom smislu slijedi dokazivanje pomoćnih hipoteza, od kojih će se u PH 1 tražiti argumenti koji će potvrditi kako se strateškim promišljanjem donošenja odluka o prihvaćanju suvremenih tehnologija dugoročno osigurava opstojnost hotela na tržištu.

Druga pomoćna hipotezu dokazivat će se teorijskim spoznajama i iskustvima drugih – *benchmarkingom*. Kao polazište koristit će se rezultati objavljenih istraživanja u stručnim i znanstvenim radovima, od kojih su za hrvatske prilike relevantna istraživanja Instituta za turizam. Kao vlastiti izvor koristit će se rezultati dobiveni empirijskim istraživanjem anketnim upitnikom.

Treću pomoćnu hipotezu, koja je usko orijentirana na korištenje CRM-a u svrhu podizanja kvalitete usluge u interakciji „hotel – gost“ dokazivat će se rezultatima provedenog terenskog istraživanja.

Unatoč velikom broju znanstvenih i stručnih radova koji se bave problematikom korištenja informacijskih tehnologija u donošenju strateških i poslovnih odluka u hotelskoj industriji, predložena tema ove doktorske disertacije nigdje nije adekvatno integralno razmatrana. Budući da tema doktorske disertacije nije u potpunosti istražena i javno prezentirana, postoji teorijsko i praktično opravdanje njezina istraživanja.

1.3 Ocjena i prikaz dosadašnjih istraživanja

Dosadašnja su istraživanja CRM-a u hotelskoj industriji brojna i datiraju od samih početaka korištenja CRM-a u hotelijerstvu 1988. godine, otkada je, kako su to uredili i klasificirali Sota, Chaudhry i Srivastava (*Customer relationship management research in hospitality industry: a review and classification*, 2019) objavljeno preko 9.000 stručnih i znastvenih istraživanja, članaka, knjiga, konferencijskih dokumenata i izvještaja. Kronološki se ta istraživanja mogu razvrstati u tri razdoblja:

1. ***Razdoblje od 1988. do 2000. godine.*** Najstariji članak koji relevantan za ovaj sustavni pregled literature objavljen je 1988. godine u *International Journal of Hospitality Management*, autora Haywooda, K. M. (1988), pod naslovom *Repeat patronage: Cultivating alliances with customers*, u kojem se naznačuje važnost njegovanja odnosa s korisnicima. Nakon 1998. god nastavljen je kontinuitet u objavljenim istraživanjima o CRM-u u ugostiteljstvu. U ovom razdoblju su objavljena 132 rada o CRM-u, od kojih se samo 11 odnosilo na hotelijerstvo. Većina radova se odnosila na tehnologiju primjene te nije bilo istraživanja o strategiji, organizaciji te struktura i kultura tijekom ove faze. Objavljena su dva citirana rada u tom vremenskom periodu i oba rada (Bowen & Shoemaker, 1998; Kandampully & Suhartanto, 2000) su se odnosila na lojalnost korisnika.
2. ***Razdoblje od 2001. do 2010. godine.*** Tijekom ove faze najvažnija je bila uporaba tehnologije u CRM-u. Značajna su bila istraživanja vezana uz uporabu tehnologije za prikupljanje, pohranu, analizu i korištenje podataka o kupcima kao marketinške baze za održavanje dugoročnih odnosa s korisnicima. Jednako tako provode se empirijska istraživanja korištenja CRM-a te analize i rasprave dobivenih rezultata. Vode se rasprave o rezultatima u raznim oblicima, kao što su zadržavanje kupaca, lojalnost kupaca, usmena predaja, ponovljena kupovina, zadovoljstvo kupaca i financijska uspješnost. Tijekom ovog razdoblja uočava se veći broj članaka vezanih za organizacijsku strukturu i kulturu (12%).
3. ***Razdoblje od 2011. do 2018. godine.*** U ovom je razdoblju objavljeno 61% svih publikacija o CRM-u u hotelskoj industriji. To jasno prikazuje da je ovo područje dobilo na važnosti znanstvenika i stručnjaka. Praćenje sinkronizacije s trendovima prethodnih godina bilo je u fokusu istraživanja. Većina članaka koji su objavljeni usredotočeni su na rezultate i koristi CRM-a, praćeni tehnologijom i odanošću. Teme koje su dominirale u tom periodu odnosile su se na vjernost (lojalnost) korisnika.

Većina znanstvenih radova na temu CRM-a u hotelskoj industriji objavljena je u specijaliziranim časopisima koji prate tematiku hotelijerstva, ugostiteljstva i turizma pa su tako prema istraživanju Sote, Chaudhry-a, i Srivastava-e (*Customer relationship management research in hospitality industry: a review and classification*, 2019, str. 8), najzastupljeniji *International Journal of Contemporary Hospitality Management* (21% svih radova), *International Journal of Hospitality Management* (14%), *Journal of Hospitality and Tourism Management* (6%) te *Journal of Hospitality Marketing & Management* (5%).

Teme koje su dominirale u tim istraživanjima bile su: 1) tehnologija, 2) rezultati, 3) programi lojalnosti i 4) percepcija potrošača-gosta

1. ***Tehnologija*** se pokazala kao najvažniji aspekt CRM-a u provedenim studijama u prošlosti. Hotelijerska industrija intenzivno koristi tehnologiju za održavanje dugoročnih odnosa sa svojim gostima. Upotrijebljena je tehnologija u različitim oblicima i platformama, poput mrežne stranice, marketinga baze podataka, stranice društvenih medija i mnogih drugih. Gilbert, Powell-Perry i Widijoso (*Approaches by hotels to the use of the Internet as a relationship marketing tool*, 1999) objavili su jedan od prvih radova na temu korištenja interneta kao CRM strategije, posebice koja se odnosi na sektor hotelijerstva. Oni su korištenjem kvalitativne metode zaključili da bi globalni internet mogao biti rješenje za izazove s kojima se suočila hotelijerska industrija krajem 20. stoljeća. Diffley, McCole i Carvajal-Trujillo (Diffley, McCole, & Carvajal-Trujillo, 2018), istražili su korištenje SCRM-a, odnosno korištenja platformi društvenih medija za održavanje odnosa s kupcima i zaključili da ono povećava inovativnost i dovodi do povećanih financijskih rezultata. Talón-Ballestero i sur. (*Using big data from Customer Relationship Management information systems to determine the client profile in the hotel sector*, 2018), istraživali su kako je moguće koristiti velike baze podataka (engl. *Big Data*) iz CRM informacijskih sustava za profiliranje gostiju. Njihovo je istraživanje pomoglo u identificiranju profila novih i stalnih gostiju hotela. Značajne su i brojne druge studije vezane uz tehnologiju, poput podataka o rođendanima, (Dursun & Caber, 2016), korištenja Facebooka (Su, Mariadoss, & Reynolds, 2015), upotreba značajki mrežne stranice (Bilgihan & Bujisic, *The effect of website features in online relationship marketing: A case of online hotel booking*, 2015), mobilna tehnologija (Anne Coussement & Teague, 2013) i informacijski sustavi (Ku, 2010).
2. ***Rezultati.*** Razumljivo je da su brojna istraživanja CRM-a posvećena razumijevanju uspješnosti i rezultatima korištenja CRM programa. Rahimi i Kozak (*Impact of customer*

relationship management on customer satisfaction: The case of a budget hotel chain, 2017) istraživali su utjecaj CRM-a na zadovoljstvo korisnika „povoljnih hotela“ Ujedinjenog Kraljevstva. Zaključili su kako CRM sustavi dovode do učinkovitog procesa rezervacija i prijava te prilagođavanja, ali isto tako da efikasni sustavi sami po sebi ne dovode do uspjeha nekog hotela, već su to i dalje bazične djelatnosti usluge ugodnog boravka i pristupačne cijene. Analiza troškova i koristi CRM-a u hotelskoj industriji proveli su Shanshan, Wilco i Eric (2011), analizu profitabilnosti radili su Iyengar i Suri (2011), korelaciju korištenja CRM-a i prihoda istraživao je Wang (2012), dok je Piccoli *(A framework for evaluating the business value of customer data in hospitality*, 2008) uspostavio okvir za ocjenu podatke o klijentima u hotelijerstvu.

3. ***Programi lojalnosti*** često su korišteni u hotelijerstvu za izgradnju dugoročnih odnosa s gostima. Brojni autori usredotočili su se na programe vjernosti i lojalnosti gostiju u istraživanju CRM-a. Najviše su na tu temu citirani članci Bowena i Shoemakera *(Loyalty: A strategic commitment*, 1998), gdje se uspostavlja povezanost CRM-a s programima lojalnosti. Xiong i sur. (2014) istraživali su odnos lojalnosti prema ponašanju i percepcije programa lojalnosti gostiju. Njihova otkrića navode da se gostima sviđa fleksibilnost za kupnju bodova u vjernosti programa te da ne vole platiti premije za brend.
4. ***Ponašanje potrošača-gosta.*** Prema Kotleru i Kelleru *(A framework for marketing management*, 2012, str. 151) ponašanje potrošača je studija kako pojedinci, grupe i organizacije biraju, kupuju, koriste i prihvaćaju robu, usluge, ideje ili iskustva kako bi zadovoljili njihove potrebe i želje. Louvieris, Driver, i Powell-Perry *(Managing customer behavior dynamics in the multi-channel e-business environment: Enhancing customer relationship capital in the global hotel industry*, 2003), usredotočili su se na razumijevanje promjena u ponašanju potrošača zbog pristupa višekanalnom pristupu internetu, a posljedično i utjecaju na odnose s gostima. Njihovi rezultati ukazuju kako interaktivni mrežni servisi mogu pomoći u privlačenju gostiju i izgradnji lojalnih odnosa s njima. Maggon i Chaudhry (E*xploring relationships between customer satisfaction and customer attitude from customer relationship management viewpoint: an empirical study of leisure travellers,* 2018) istraživali su odnos zadovoljstva korisnika i stavova gostiju iz perspektive CRM-a, dok su se Kim, Knutson i Vogt (*Post trip behavioral differences between first-time and repeat guests: a two-phase study in a hospitality setting*, 2014) usredotočili na razlike u ponašanju gostiju koji prvi put dolaze i stalnih gostiju hotela te ustanovili da su stajališta onih gostiju koji prvi put posjećuju neki hotel povoljnija od onih stavova koje iskazuju stalni gosti.

Hrvatski turistički prostor, zbog svoje raznolikosti vrsta i podvrsta različitih vidova turizma, zahvalan je za jednako toliko istraživanja. Obrazovni srednjoškolski, visokoškolski sustav s brojnom znanstvenom populacijom proizveo je zavidan broj istraživanja u okvirima završnih ili diplomskih stručnih radova te stručnih i znanstvenih, magistarskih i doktorskih radova koja su, kao i ovaj rad, imale inkorporirano i odgovarajuće terensko istraživanje.

Međutim valja naglasiti kako neovisno o činjenici da se radi o kvalitetnoj stručnoj i znanstvenoj osnovi protek vremena zahtijeva njezinu permanentnu nadogradnju. Naime, promjene koje su nastupile u novom mileniju, posebice u segmentu informacijske i komunikacijske tehnologije, uvelike su promijenile turiste, turistička putovanja i cjelokupnu turističku djelatnost. Turist više nije objekt turizma koji zavisi od ponude i potražnje već je subjekt koji aktivno sudjeluje u kreiranju svojeg putovanja i koji želi u što kraćem vremenu vidjeti i doživjeti više, koji traži „vrijednost za novac“, ovisi samo o svojem „pametnom telefonu“. Promjene koje je inicirala pojava širokopojasnog interneta i mobilna mreža četvrte generacije (4G) kao podloga za brojne aplikacije učinile su mnoga dosadašnja istraživanja arhaičnim. Njihovo ažuriranje postiže se samo novim istraživanjima.

Isto to vrijedi za realni sektor. Menadžeri u turizmu, koji su razumjeli poruku nove tehnologije, ostvaruju svoju konkurentnost na turističkom tržištu stalno nadograđujući svoja znanja, unaprjeđuju kvalitetu i slijede aktualne trendove.

Ogledno istraživanje relevantno za temu rada o menadžerskim potrebama za informacijskom tehnologijom u hotelskoj industriji provedeno je početkom milenija (2002. godine), kada je IT u Hrvatskoj bio u usponu, ali infrastruktura i brzina prijenosa podataka su s dvadesetogodišnjim odmakom neusporedive. Međutim usporedbe radi važno je sagledati rezultate provedenog istraživanja kako su ga prezentirali Galičić i Cerović (Menadžeri hotela i informacijska tehnologija, 2004). Istraživanje o percepciji hotelskog menadžmenta prema uporabi IT-ja u hotelskom poslovanju provedeno je na uzorku 91 direktora iz 31 hotelskog poduzeća iz cijele Hrvatske. Rezultati istraživanja sažeto ukazuju: „da u određenoj mjeri, gotovo svi hotelski objekti koriste informacijsku tehnologiju i da su njihovi menadžeri svjesni potrebe daljnje implementacije modernih alata, što ih nudi informacijska tehnologija“ (Galičić & Cerovac, Menadžeri hotela i informacijska tehnologija, 2004, str. 179).

Više od 77% ispitanika smatralo je da informacijska tehnologija povećava opću učinkovitost svih hotelskih operacija. Nasuprot tome 44% menadžera smatralo je kako primijenjena informacijska tehnologija nije proizvela zadovoljavajuće visoku produktivnost i time opravdala uložene troškove. Treba se uzeti u obzir da je istraživanje provedeno u trenutku intenzivnog

uvođenja IT-ja u hotelijerstvo, ali da postojeće strukture još nisu bile spremne na promjene i prednosti koje ta tehnologija nudi, što autori istraživanja nazivaju „paradoksom produktivnosti“ koji je „produkt lošeg menadžmenta koji nije uspio povezati poslovnu strategiju s mogućnostima tehnologije“ (Galičić & Cerovac, Menadžeri hotela i informacijska tehnologija, 2004, str. 184).

Sljedeće istraživanje relevantno za temu DD-a provedeno 2010. godine bilo je istraživanje o razvijenosti informacijskih sustava velikih hotelskih poduzeća u Hrvatskoj prema modelu zrelosti sustava, koje su proveli Grbin Praničević, Pivčević i Garača na uzorku od 39 hotela, odnosno 24 hotelska poduzeća. Kao elemente razvijenosti IS-a ocjenjivani su (Grbin Praničević, Pivčević, & Garača, 2010, str. 196): pohranu podataka, pouzdanost, integralnost, umreženost, pristup informacijama unutar hotela, pristup informacijama izvana prema hotelu, ciklus obnove hardvera, ciklus obnove softvera, razinu upravljačke podrške, dostupnost, sigurnost i informatičku pismenost.

Razvijenost nekog informatičkog sustava usko je povezana s razvijenošću komponenti koje obilježavaju taj sustav. Ukupna prosječna ocjena svih dvanaest elemenata iznosila je 3,25, što upućuje na relativno dobar rezultat (radilo se o 2010. godini). Međutim istraživanje je pokazalo kako su elementi „pohrana podataka“ i „informatička pismenost“ najlošije ocijenjeni, što pokazuje kako „ulaganja u informacijske sustave nisu praćena adekvatnim ulaganjima u ljudske resurse“ (Grbin Praničević, Pivčević, & Garača, 2010, str. 196).

Rezultati provedenog istraživanja samo nastavljaju trend rezultata prethodnih istraživanja.

1.4 Znanstvene metode istraživanja

Ostvarivanje ciljeva i zadataka postavljenih u ovoj doktorskoj disertaciji nametnulo je potrebu da se predmetu istraživanja pristupi sustavno, povijesno i dijalektički. To je ujedno značilo da se relevantne činjenice, uvjeti i okolnosti promatraju na znanstveni način i da se o njima prosuđuje kroz međusobnu povezanost i interakciju višedisciplinarno i višedimenzionalno. S obzirom na to, u istraživanju će biti korištene metode analize i sinteze, metode sustavne analize, deskripcije te logičke metode, i to ponajviše u kombinaciji induktivne i deduktivne metode. Primijenit će se i povijesna, genetička metoda kako bi se istražila dosadašnja saznanja, razvoj i promjene predmeta ovog istraživanja, što može poslužiti kao okvir za daljnja istraživanja. Obilato će biti korištene i kvantitativno-kvalitativne metode povezane s metodom komparacije

prostornih i vremenskih značajki. Jedan dio ovih metoda, uz određenu prilagodbu, svrhovito će biti primjenjivan i u samom izlaganju zaključnih razmatranja. Pritom će, kao oblik argumentacije ili jednostavne ilustracije, biti korištene tablice statističkih nizova prilagođene danom tekstu i slična uobičajena tehnička sredstva predočavanja. Bit će primijenjen i uobičajen metodološki instrumentarij, tako da će *desk*-istraživanja biti temeljena na raspoloživoj dokumentaciji u koncipiranju relevantnog sadržaja doktorske disertacije.

Empirijski dio rada oslanja se na kvantitativno istraživanje, točnije anketno istraživanje kao temelj za identifikaciju određenog fenomena, pitanja u anketnom upitniku zatvorenog tipa namijenjenog uzorku poznavatelja od kojih se traži decidirano izjašnjavanje o postavljanim pitanjima. Ovakva je metoda istraživanja posebno učinkovita u sagledavanju društvenog konteksta populacije te traženju i dobivanju informacija o percepcijama, stavovima i ponašanjima pojedinaca.

Problem koji dolazi do izražaja u prikupljanju mišljenja i stavova hotelskih menadžera o korištenju i iskustvima s CRM-om nalazi se u činjenici da hrvatski hotelijeri nisu još uvijek u većem broju prihvatili mogućnosti koje suvremene informacijske tehnologije pružaju u upravljanju odnosima s gostima. Neki od oblika CRM-a implementirani su u velikim hotelima visoke kategorije dok je kod srednje velikih hotela ta primjena tek sporadična. Većina menadžera smatra da je sama nazočnost na mrežnom prostoru dovoljna, a odnose s kupcima izjednačavaju s aplikacijama za rezervacije. Stoga je uzorak relativno mali, ali svakako reprezentativan s obzirom na populaciju.

Rezultati ankete temelje se na obradi i analizi dobivenih podataka uz pomoć IBM SPSS Statistics 24 programa.

1.5 Kompozicija doktorske disertacije

Struktura disertacije započinje opisom predloženog istraživanja, postavljanjem glavne i pomoćnih hipoteza te definiranjem svrhe i cilja istraživanja. Uvodno se daje ocjena i prikaz dosadašnjih istraživanja značajnih za temu rada. S obzirom na kompleksnost teme, navest će se i obrazložiti vrela istraživanja kao i spoznaja do kojih se došlo njihovom uporabom. Od posebnog su značaja dosadašnji radovi koji s teorijskog aspekta približavaju znanja iz područja informacijskih tehnologija i strateškog menadžmenta, čime se postiže interakcija potrebna za

razumijevanje posebnosti vezanih uz upravljanje odnosima s kupcima u specifičnom prostoru proizvodnje i prodaje usluga koje obilježavaju hotelsku industriju.

U ovom su poglavlju naznačene i osnovne znanstvene metode koje će se koristiti tijekom istraživanja te prezentirana predviđena kompozicija doktorske disertacije.

U drugom se dijelu rada s teorijskog gledišta analizira *informacijski sustav kao resursna osnova poslovanja poduzeća*, što je ujedno i naslov drugog poglavlja. Svrha je ovog dijela rada upoznavanje s temeljnim značajkama informacijskog sustava, koji prethode informacijskom poslovnom sustavu. Informacijski poslovni sustavi sustavno se razmatraju počevši od definiranja pojma, navođenja vrsta i funkcija poslovnih sustava do njihova razvoja i koncepta životnog ciklusa. Posebice se analizira upravljačka struktura IS-a te mogućnosti integriranja u sve poslovne i organizacijske strukture, u jedinstveni integralni poslovni sustav.

U nastavku istog poglavlja pokušava se utvrditi kakav je i koliki utjecaj informacijskog poslovnog sustava na konkurentnost poslovanja poduzeća te usvojene spoznaje argumentirano obrazložiti.

U trećem dijelu rada se u skladu s naslovom *Strateški menadžment hotelskog poduzeća kao poluga izvrsnosti poslovanja* nastoji utemeljeno ukazati na značaj strateškog upravljanja poslovnim sustavima u hotelskoj industriji. U tom smislu, uvodno se elaboriraju važnija obilježja hotelskog poduzeća kao poslovnog sustava, razmatra okruženje, organizacija i životni ciklus hotelskog poduzeća. U nastavku se analiziraju strateški menadžment u hotelskom poduzeću, razine te funkcije menadžmenta s naglaskom na specifičnosti osobina menadžera u hotelskom poduzeću.

Krucijalnost primjene informacijskih tehnologija kao faktor uspješnom menadžerskom odlučivanju u hotelskom poduzeću naslov je četvrtog dijela rada u kojem se u sklopu sagledavanja sustava odlučivanja u hotelskom poduzeću analiziraju vrste odluka i modeli odlučivanja te argumentirano pojašnjava distinkcija između poslovnog i menadžerskog odlučivanja. Potom se detaljno raščlanjuju sustavi za podršku u menadžerskom odlučivanju kao sustavi podrške odlučivanju (DSS) i grupnom odlučivanju (GDSS), za podršku vrhovnom menadžmentu (ESS) te sustavi za obradu transakcija. Pored navedenih operativnih sustava posebnu pozornost iziskuju upravljački sustavi poput menadžerskog informacijskog sustava – MIS-a. U suvremenim hotelskim poduzećima informacijski su sustavi inkorporirani u sve ili gotovo sve poslovne centre odgovornosti hotela, koji čine informacijske podsustave podređene MIS-u.

Sagledavanje cjelokupnosti informacijskog sustava hotelskog poduzeća u ovom poglavlju omogućuje argumentirano donošenje zaključka kako je informacijska tehnologija, pored podrške menadžerskom vođenju, strateškim dugoročnim odlukama, objedinjavanju praćenja poslovnih procesa proizvodnje i prodaje usluga, nadasve bitan činitelj izgradnje organizacijske kulture hotelskog poduzeća.

Peti dio rada *Poslovna inteligencija kao nova paradigma inoviranja koncepcije razvoja hotelskog poduzeća* poglavlje je u kojem se sublimiraju prethodno usvojene teorijske spoznaje neophodne za razumijevanje i korištenje učinaka poslovne inteligencije. Naglašava se značaj poslovne inteligencije u funkciji anticipiranja koncepcije razvoja hotelskog poduzeća u sinergijskom efektu novih strateških usmjerenja hotelskog poduzeća. Upravljanje odnosima s potrošačima odnosno gostima u fokusu je interesa istraživanja te se teorijskom aspektu CRM-a posvećuje veći dio ovog poglavlja. Jednako tako analizira se uloga CRM-a kao koncepta vrijednosti u implementiranju strateškog procesa u hotelskom poduzeću, razlozi uvođenja i ciljevi CRM-a u hotelskim poduzećima te uspostava i efikasnost CRM modela u hotelska poduzeća. Detaljno se pojašnjavaju funkcije upravljanja odnosima s klijentima, kao i inovacije koje su posljedica evoluiranja CRM-a u SCRM (*Social Customer Relationship Management*), odnosno u područje društvene interakcije s klijentima. Nadalje se razmatraju mogućnosti pristupa velikim bazama podataka (*Big Data*) koje su izgrađene tijekom vremena u hotelskim lancima ili na neki drugi legalan način. Poglavlje, a time i teorijski dio rada, završava iznošenjem argumenta o važnosti prilagodbe hotelskog poduzeća politici novih tržišnih vrijednosti.

Empirijsko istraživanje operativne efikasnosti i inovativnosti primjene ICT tehnologije u poslovanju hotelskih poduzeća u Republici Hrvatskoj šesti je dio rada u kojem se terenskim istraživanjem metodom anketnog upitnika traže od relevantnih čimbenika strateškog promišljanja u velikim hotelima odgovori o efikasnosti i inovativnosti primjene ICT tehnologije u njihovu poslovanju. Od ispitanika ***poznavatelja*** tražilo se iznošenje subjektivnih stavova proizašlih iz osobnog iskustva te komunikacije s gostima, dobavljačima, turoperatorima, partnerima i lokalnom zajednicom.

Prvom skupinom pitanja želio se steći uvid u aktualnom stupnju elemenata integriranih komunikacijskih usluga ITC-a u hotelima. Drugu skupinu čine ocjene funkcija CRM sustava i ocjene korisničke podrške. Treća skupina pitanja odnosi se na ocjenu postojećih i procjenu budućih razvojnih elemenata CRM-a. Posljednja skupina pitanja traži od ispitanika konkretne

odgovore o postojećoj integriranosti ICT usluga u hotelu, otvorenosti za implementaciju CRM sustava te budućnosti CRM-a.

Prikupljeni odgovori bit će analizirani, razvrstani, statistički obrađeni te će se provesti rasprava i donijeti odgovarajući zaključci koji će potvrditi, odnosno opovrgnuti postavljene hipoteze istraživanja.

Na kraju slijede zaključna razmatranja, popis korištenih bibliografskih jedinica, popis vizualija te odgovarajući prilozi.

INFORMACIJSKI SUSTAV KAO RESURSNA OSNOVA POSLOVANJA PODUZEĆA

Ubrzani razvoj informacijske tehnologije još od polovice 20. stoljeća unosi promjene u načine života i rada suvremenog čovjeka. Oni koji pružaju otpor tim promjenama – bilo pojedinci ili poslovni subjekti – suočavaju se s problemima poslovanja u novonastalom poslovnom i tehnološkom okruženju. Telefon, telefaks, televizija, mehanograf i računala započeli su elektroničku eru i olakšali komunikaciju i protok informacija. U poslovnom smislu to je značilo brisanje granica poslovanja, razvoj multinacionalnih kompanija, brzinu transakcija i prijenosa podataka. Prelazak na digitalnu tehnologiju i pojava interneta 80-ih godina 20. stoljeća označeni su kao „treća industrijska revolucija“. Njezinom pojavom nestali su brojni glomazni poslovni sustavi, ali se formirali novi, manji i fleksibilniji, oslobođeni prepisivanja i arhiviranja. „Četvrta industrijska revolucija“ ili „novomilenijska tehnološka revolucija“ proces je u kojem tehnologije poput umjetne inteligencije, autonomnih vozila i interneta prožimaju fizičke živote ljudi. Ona „zamagljuje granice između fizičke, digitalne i biološke sfere“ (Schwab, 2018).

Razvidno je kako se IT razvija progresivno te stoga svako ulaganje u informatičku tehnologiju za poslovne subjekte prvenstveno postaje preduvjet opstanka na globaliziranom tržištu, a ne samo pitanje izbora poslovne strategije.

Kako bi se detaljnije obrazložile uvodno navedene postavke u ovom poglavlju se razmatraju: 1) teorijske determinante informacijskog sustava, 2) integralni informacijski poslovni sustav, 3) utjecaj informacijskog poslovnog sustava na konkurentnost poslovanja poduzeća i 4) utjecaj razvoja informacijske tehnologije na hotelsku industriju.

1.6 Teorijske determinante informacijskog sustava

Informacijska tehnologija, posebice njezin segment namijenjen poslovnim sustavima, ispostavilo se ima najkraći životni vijek od svih drugih tehnologija. Otprilike svake dvije godine uvode se novi operativni sustavi koji se, doduše, nadograđuju na postojeće, ali onda nastaju problemi s kapacitetom (RAM), brzinom, prostorom za pohranjivanjem podataka i ranjivošću

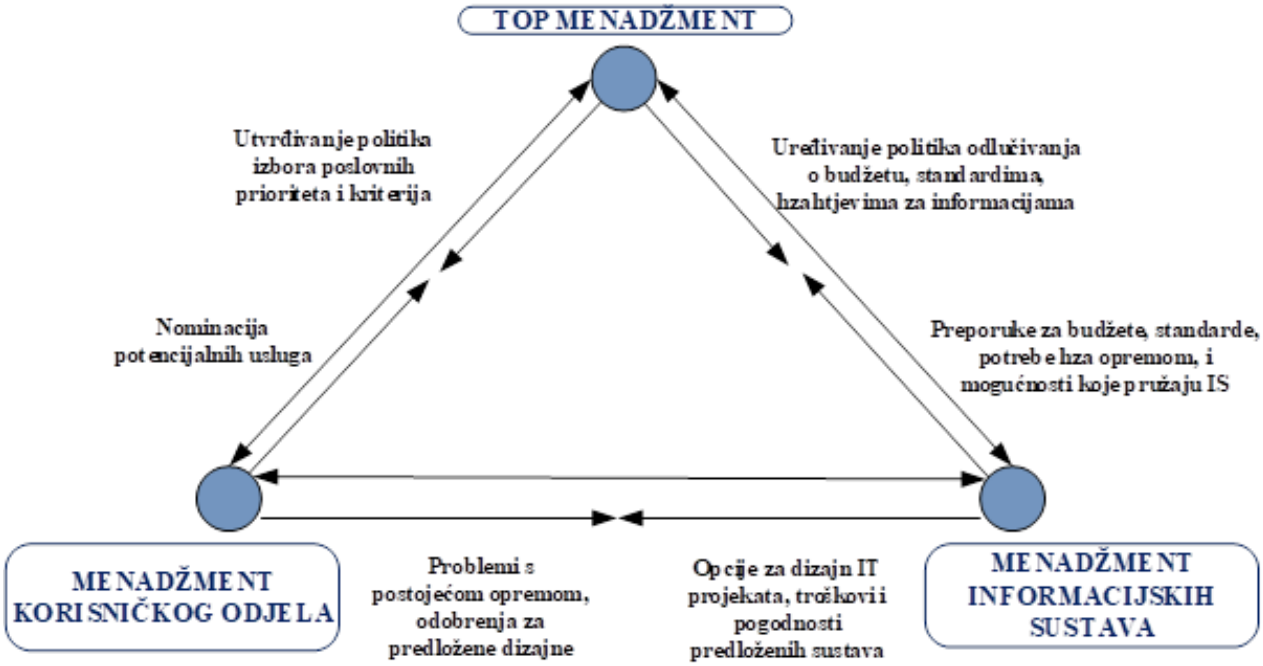
sustava. Brojne nove poslovne aplikacije i njihove inačice jednostavno ne podržavaju „zastarjeli“ operativni sustavi.

Kolika je realna poslovna vrijednost informacijske tehnologije, u znanstvenim i stručnim krugovima vode se brojne rasprave. Zagovornici korištenja informacijske tehnologije u poslovanju argumentiraju njezin doprinos povećanjem produktivnosti, stvaranjem dodane vrijednosti te značajnim učincima na poslovanje općenito. Nasuprot njima postoje i stajališta kako samo korištenje IT-ja ne proizvodi bitnije učinke na poslovne rezultate.

Stoga, unatoč spoznajama kako su ekonomske veličine produktivnost, novostvorena vrijednost i profitabilnost međusobno povezane, utjecaj IT-ja na svaku od njih treba posebno analizirati. Rezultati mnogih istraživanja pokazuju da ulaganja u IT rezultiraju povećanjem produktivnosti i dodane vrijednosti, ali kako navode Groznik i Kovačič (2002, str. 20), „ne može se egzaktno utvrditi veza između ulaganja u IT i poslovnih rezultata“.

Upravljanje informacijskim sustavom, kako navodi Muller (2001, str. 589), „zapravo predstavlja potpornu djelatnost svim poslovnim funkcijama i poslovnim procesima te predstavlja mogućnost unaprjeđenja njihova funkcioniranja“.

Slika 1. Kontekst funkcioniranja odjela informatike i model upravljanja informacijskim sustavom poduzeća.



Izvor: Mulller, J., 2001. Upravljanje informacijskom tehnologijom u suvremenim tvrtkama te hrvatska poslovna praksa korištenja informacijskih tehnologija. *Ekonomski pregled,* 52(5-6), str. 589.

Informacijska tehnologija inkorporirana je u poslovni sustav poduzeća i egzistira kao ključni resurs koji omogućuje razvoj svih drugih komponenti poslovnog sustava.

Suvremene informacijske tehnologije izmijenile su način na koji djeluje cjelokupni poslovni sustav. Promijenile su se navike korisnika, kao i sama interakcija korisnika s proizvodom i proizvođačem.

Može se zaključiti kako su poslovni sustavi, ali i tržište ne kojem djeluju, evoluirali u onoj mjeri koliko je evoluirala i informacijska tehnologija. Ulaskom informatike u poslovni sustav stvorila se kauzalna veza između ta dva sustava. Problem je jedino u tome što informacijska tehnologija ima progresivan razvoj koji poslovni sustavi, posebice veliki i inertni, ne mogu dovoljno brzo pratiti. Kako bi zadržao poziciju na tržištu, poslovni sustav mora sustavno investirati u razvoj svojeg informatičkog sustava i time ulazi u spiralu konstantnog ulagana u informacijske inovacije sa svrhom održavanja poslovnog sustava.

Kako bi se dobio sveobuhvatan uvid u poslovnu vrijednost ulaganja u IT, osim pozitivnih financijskih povrata, neophodno je istražiti vrijednosti učinka koje su one polučile. Preciznije potrebno je „fokusirati se na vezu između IT investicija i rizika njihova neprihvaćanja“ (Otim, Dow, Grover, & Wong, 2012, str. 161).

1.6.1 Pojam i definicije poslovno-informacijskog sustava (PIS-a)

Definiranje poslovno-informacijskog sustava (PIS-a) promjenjivo je sukladno s promjenama informacijske tehnologije i time podložno stalnom dopunjavanju i korigiranju. Stoga mnogi autori sve više pribjegavaju uopćavanju, odnosno kako je PIS prisutan u gotovo svim djelatnostima, smatraju ga samorazumljivim pojmom. Naime, računalnim aplikacijama namijenjenim kao podršci poslovnom sustavu je „svejedno“ koristi li se njima neki obrtnik, OPG-ovac ili velika energetska tvrtka. Kapacitet prikupljenih informacija i podataka (memorija) i brzina obrade podataka (procesor) dizajnirani su na način da se mogu proširivati i ubrzavati prema potrebama korisnika, s mogućnostima pristupa putem mobilnih uređaja i korištenjem *cloud* tehnologije. PIS uključuje ljude, sredstva, poslove i sve ostalo što u složenoj interakciji ostvaruje neki cilj. Tijekom poslovanja prikupljaju se velike količine podataka koje je vrijedno dubinski analizirati kako bi se pronašle nove i vrijedne informacije. Za njihovo prikupljanje, organiziranje, pohranjivanje, pretraživanje i upravljanje, koriste se sustavi za upravljanje informacijskim sadržajima.

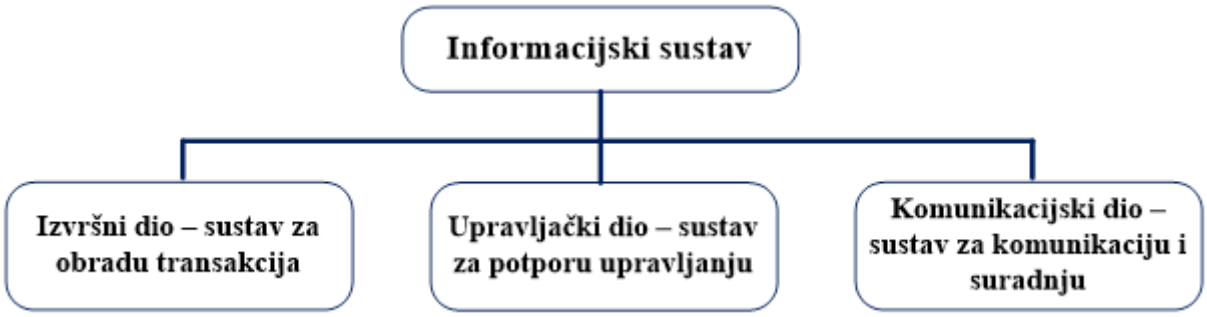
U tom kontekstu moguće je izdvojiti definiciju PIS-a koju navode Varga i Strugar (*Informacijski sustavi u poslovanju*, 2016): „PIS uključuje unos, obradu, isporuku, pohranjivanje i druge upravljačke aktivnosti, kojima se podatci pretvaraju u informacije“. Poslovni informacijski sustavi su infiltrirani u sve ljudske aktivnosti, od različitih udruga građana, sportskih i zabavnih organizacija, kulture i umjetnosti, do državnog aparata i gospodarstva.

Kao takvi postali su nezaobilazan i sastavni dio poslovanja hotelske industrije. Svojim djelovanjem potaknuli su promjene u ponašanju i promišljanju svih hotelskih djelatnika, od domara do menadžera hotela. Informatika je prisutna u svim, pa i najmanjim hotelima koji posjeduju bar jedno računalo za obradu osnovnih podataka o gostu i vođenju administracije, ali to ne čini informacijski sustav primjerenim potrebama suvremenog hotelijerstva.

1.6.2 Dijelovi informacijskoga sustava

Informacijski sustav može poduprijeti obavljanje različitih poslovnih procesa. Način na koji ih može podržavati ovisan je o obilježju procesa pa se temeljem toga informacijski sustav može podijeliti na dijelove, kako je to predočeno narednom slikom.

Slika 2. Dijelovi informacijskog sustava



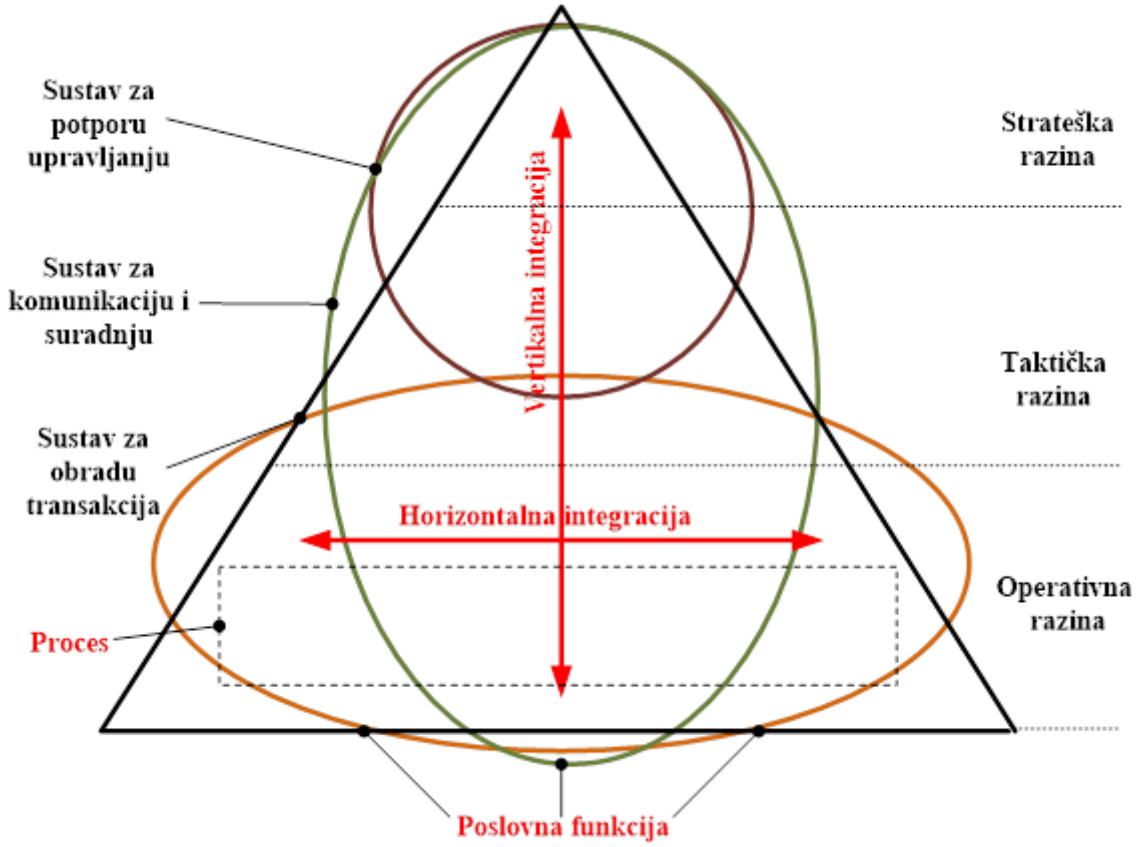
Izvor: Varga i Strugar ur., Informacijski sustavi u poslovanju, 2016., str. 9.

- Izvršni dio – podržava izvršne procese u poduzeću. Izvršnim se procesima obavljaju poslovi osnovne djelatnosti poduzeća kojima se, u pravilu, mijenjaju stanja poslovanja. S obzirom na to da se dokumentiranje promjena stanja odvija transakcijama, taj se dio informacijskoga sustava uobičajeno imenuje „sustavom za obradu transakcija“.

- Upravljački dio – podržava upravljačke procese u poduzeću. Taj se dio informacijskoga sustava imenuje „sustavom za potporu upravljanju“. Upravljački dio preuzima podatke iz izvršnoga dijela informacijskoga sustava te podatke iz vanjskih izvora kako bi kreirao informacije potrebne upravljanju i odlučivanju. Pri kreiranju informacija koristi se brojnim analitičkim, upravljačkim ili specifičnim obradama ili aplikacijama.
- Komunikacijski dio – podržava procese koji omogućuju komunikaciju, suradnju i informiranje među sudionicima poslovanja. Taj se dio naziva sustavom za komunikaciju i suradnju. U funkcioniranju poduzeća sudjeluje niz sudionika unutar poduzeća (zaposlenici) i izvan njega (klijenti, poslovni partneri, javna administracija). Oni međusobno surađuju i komuniciraju, u timu ili samostalno.

Struktura integriranog informacijskog sustava predočava se narednom slikom.

Slika 3. Struktura integriranog informacijskog sustava



Izvor: prema Varga i Strugar ur., Informacijski sustavi u poslovanju, 2016., str. 11.

Iz slike 3. uočljivo je kako integrirani informacijski sustav na operativnoj, odnosno izvršnoj razini ima sustav za obradu transakcija, na koji se nastavlja sustav za potporu upravljanju, a cijeli je informacijski sustav isprepleten sustavom za komunikaciju i suradnju.

U vertikalno-integriranome informacijskom sustavu postignuta je povezanost podataka unutar procesa pojedinih funkcijskih područja (primjerice nabave, proizvodnje ili prodaje) najniže razine (primjerice transakcija u maloprodaji) s procesima upravljanja na višim razinama (primjerice s izvještajima o analizi prodaje za glavnoga direktora).

U horizontalno-integriranom informacijskom sustavu može se pratiti poslovni proces koji se rasprostire kroz više funkcijskih područja.

Primjerice, nakon što prispije rezervacija gosta, integrirani informacijski sustav može ju prihvatiti, proslijediti „automatski“ u službu prodaje, gdje će potvrditi rezervaciju gosta, odnosno njegovom informacijskom sustavu poslati predračun, službi recepcije, službi ugostiteljskih usluga, kako bi se mogli izraditi planovi proizvodnje usluga te računalno voditi proces proizvodnje; učinke prodaje menadžer će moći promatrati i analizirati kroz analitički dio informacijskoga sustava itd.

Osnovni proces u poslovnom sustavu, kako navode Galičić i Šimunović *(Informacijski sustavi i elektroničko poslovanje u turizmu,* 2006, str. 131) jest „upravljački proces sa svoje dvije komponente, organizacijskim procesom i informacijskim procesom“.

Današnji informacijski procesi potpomognuti računalnom tehnologijom ne realiziraju svoje funkcije samo na operativnoj razini, već transformiraju i oblikuju podatke u problemsko orijentirane informacije za potporu odlučivanju na nadzornoj i upravljačkoj razini poslovnog sustava. Galičić i Šimunović (2006, str. 132) zaključuju kako „uspješnost poslovnog sustava i konkurentska prednost na tržištu najizravnije postaju ovisne od upravljanja podatcima i informacijama kao strateškim resursima“.

1.7 Integralni informacijski poslovni sustav

Poslovanje iziskuje implementaciju sve kompleksnijih poslovnih procesa podržanih različitim softverskim rješenjima, često uz interakciju s vanjskim okruženjem. Instrumenti integracije aplikacija trebaju omogućiti integraciju kompleksnih informatičkih sustava, uz pridržavanje mogućnosti dodavanja novih radi podrške novim poslovnim funkcijama. Pored samih aplikacija integrirani informacijski sustavi, kako navode (Martinčić, Šmalcelj, & Ljubešić, 2010), „uključuju i sistemsku programsku podršku te sklopovsku i mrežnu opremu“.

Integrirani informacijski sustav omogućuje unos, obradu i korištenje informacija u potpori odvijanju većine poslovnih procesa hotelskog poduzeća. Procesuiranje podataka obavljaju specijalizirani softverski programi. Kada su u pitanju složeniji poslovni procesi koji iziskuju rad međusobno integriranih aplikacija, tada se to u pravilu ostvaruje programskom podrškom srednjeg sloja (engl. *Middleware*).

Softverski alati, zajedno s programskom potporom srednjeg sloja i baze podataka, za svoje djelovanje iziskuju određenu podlogu odnosno platformu. Platformu Martinčić, Šmalcelj i Ljubešić (2010, str. 3) definiraju kao „komplet sastavljan od računala i pripadajućeg operacijskog sustava, uz eventualni dodatak okruženja kao što su Java ili .NET radno okruženje (engl. *Framework*)". Povezivanje više računala kako bi se omogućio prijenos podataka odvija se putem računalne mreže zasnovane na TCP/IP skupu protokola, a podršku sklopovskim sustavima pružaju instrumenti kao što su „osiguranje neprekidnog napajanja, klimatizacija, sustav za gašenje požara itd" (Martinčić, Šmalcelj, & Ljubešić, 2010, str. 3). Temeljne komponente integriranog informatičkog sustava su sljedeće:

1. ***Radne stanice*** **–** podrazumijevaju računala namijenjena za unos i očitanje podataka. U poduzeću se koristi za službenu, ali i neslužbenu razmjenu informacija, što utječe na njezinu sigurnosnu izloženost.
2. ***Poslužitelji*** – serveri pružaju platformu aplikacijama čija je svrha ostvarenje računalnih usluga na kojima se zasnivaju poslovni procesi.
3. ***Računalna mreža*** **–** omogućuje međusobnu komunikaciju povezanih računala. Sastoji se od aktivne mrežne infrastrukture (preklopnici, usmjerivači) i pasivnih komunikacijskih kanala. Sve su informatičke mreže direktno ili indirektno povezane s vanjskim okruženjem, što iziskuje opreznost i metodičnost u pristupu osiguranja stabilnosti računalne mreže.

Kako bi se ostvarilo efikasno upravljanje sigurnosnim instrumentima, u informacijskom sustavu zadaće upravljanja neophodno je generalizirati i centralizirati sa svrhom dostizanja dosljednosti i sužavanja prostora za eventualne pogreške. Kako bi se to ostvarilo, primjenjuje se grupa sustava namijenjenih podršci upravljanju informacijskim sustavom (engl. *Information System Management*).

Informacije se, prema Martinčić, Šmalcelj, i Ljubešić (2010, str. 5), mogu smatrati sigurnima „onda kada raspolažu minimalno sa sljedećim svojstvima: a) dostupnost, b) integritet i c) povjerljivost".

Nedostatkom nekog od navedenih minimalnih svojstava slabi se sigurnost informacije te time narušava funkcioniranje pripadajućeg poslovnog procesa. Takva ugrožavanja mogu prouzročiti razna slučajna ili namjerna djelovanja unutar informacijskog sustava ili iz okruženja. Instrumenti informatičke sigurnosti odupiru se takvim prijetnjama. Valja imati u vidu kako su resursi koji se izdvajaju za sigurnost informatičkog poslovnog sustava najčešće ograničeni te je teško dostići apsolutnu sigurnost informacija. Održavanje informatičke sigurnosti na željenoj razini ovisi o procjeni veličine rizika od vanjske ugroze (hakerski napad) ili neovlaštenog pristupa računalima, što onda određuje splet mjera za zaštitu informacija kako bi se mogući gubitak sveo na najmanju moguću mjeru.

Informatički sustavi u hotelskim poduzećima bitno se ne razlikuju od uobičajenih informatičkih sustava. Informatički su dizajnirani i implementirani na način da ispunjavaju ograničene zahtjeve na karakteristike, pouzdanost, sigurnost i fleksibilnost. Osnovni zadatak je zadovoljavanje uravnoteženog rada rezervacijskog sustava, dok se informacijskim i komunikacijskim tehnologijama posvećuje manja pozornost.

1.8 Utjecaj informacijskog poslovnog sustava na konkurentnost poslovanja poduzeća

Poslovni informatički sustav distribuira podatke i informacije za potrebe poslovanja, što se realizira posredstvom informacijsko-komunikacijske tehnologije.

Gotovo svi informatički sustavi kroz podršku informacijskim sustavima tvrtkama služe za podršku odlučivanju, no prema stupnju podrške ih se može stupnjevati kao (Garača & Ćukušić, 2011, str. 1): „deskriptivne (engl. *descriptive*), objašnjavajuće (engl. *explamatory*), prediktivne (engl. *predictive*) i odlučujuće (engl. *decision making*)“, koje se u nastavku detaljnije obrazlažu.

1) ***Deskriptivni stupanj*** podrške odlučivanju podrazumijeva pripremu izvještaja na osnovi stupnjevanja, ponderiranija i izračuna relacija. Deskriptivna razina podrške odlučivanju podržava klasični menadžerski, odnosno sustav računalno podržanih izvještaja.
2) ***Objašnjavajući stupanj*** podrške odlučivanju je viša razina potpore koja kroz pregled uzorka postojećeg stanja, uporabom matematičkih i statističkih metoda, pojašnjava uzroke.

3) ***Prediktivni stupanj*** podrške zasniva se na korištenju odgovarajućih modela sposobnih da daju na temelju provedenih scenarija odgovore na pitanja o vrijednostima promatranih veličina.
4) ***Odlučujući stupanj*** podrške je najviši stupanj koji uključuje i primjenu umjetne inteligencije. Ne podrazumijeva isključivo donošenje odluka, već je i podrška za formiranje ciljeva.

Budući da su informacijski sustavi važna poluga poslovanja, menadžment mora voditi računa o njihovoj raspoloživosti, pouzdanosti, rizicima korištenja i upravljanja kako bi mogao koristiti sve prednosti IT-ja kao vrijednog resursa poduzeća. Upravljanje poslovnim informacijskim sustavom čini ključan segment upravljanja cjelokupnim poslovanjem, koji uključuje odgovornost za pouzdanost sustava, održavanje informatičke infrastrukture i upravljanje investiranjem u informatiku sukladno poslovnim prioritetima.

Upravljanje informatikom i poslovnim informacijskim sustavom prema Spremiću je (Spremić, 2007, str. 311) „skup tehnika i načina kojima najviši menadžment 'ovladava' primjenom informatike u poslovanju, ulaganjima u informatiku, uspješnosti i rizicima njezina korištenja, ali i preuzima, odnosno dodjeljuje odgovornost za kontrolu provedbe informatičkih i svih aktivnosti“.

1.8.1 Strateška važnost primjene IT-ja

Strateški značaj primjene IT-ja u poslovanju prije svega se ogleda kroz međusobnu povezanost s organizacijskim značajkama poduzeća. Kriva procjena može ozbiljno djelovati na poslovanje i položaj hotelskog poduzeća na tržištu, stoga je strateške ciljeve poslovanja neophodno uskladiti s ciljevima IT-ja (Boban & Babić, 2014, str. 64). Narednom slikom predočava se strateški potencijal primjene IT u poslovanju.

Slika 4. Strateški potencijal primjene IT-ja u poslovanju

PODRUČJE	UTJECAJ IT-a
Globalizacija poslovanja	IT jednostavno i jeftino prenosi informacije na velike udaljenosti i ukida vremenska i prostorna ograničenja u poslovanju
Reinženjering poslovnog procesa	IT podržava procesni pristup, timski rad i radikalnu promjenu poslovanja
Brzina reakcije na tržišne uvijete	IT podiže razinu operativne efikasnosti, automatizira i ubrzava procese, utječe na skraćenje poslovnih ciklusa čime omogućuje praćenje dinamike tržišta i bržu reakciju na strateške prijetnje
Povezanost, integrativnost, strateška partnerstva	IT povezuje poslovne sustave i sve sudionike procesa koji imaju potrebu komunicirati, čime se pojednostavljuje organizacijska struktura, postiže visoka razina integracije poslovanja i izbjegava uloga posrednika u transakcijama
Upravljanje ljudskim resursima	IT omogućuje pohranjivanje, distribuciju i stvaranje novog znanja čime utječe na povećanje intelektualnog kapitala kompanije
Praćenje i kontrola	IT prati status pojedinih aktivnosti ili procesa dok se zbivaju te se korekcije i ispravci mogu provoditi dok proces još traje
Unaprjeđenje kvalitete	IT omogućuje brzu analizu procesa, a njegova inovativna primjena može znatno unaprijediti kvalitetu usluge prema krajnjim kupcima
Orijentacija na kupca i proizvodnja prema želji pojedinca	IT omogućuje pojedinačnu efikasnu komunikaciju s milijunima kupaca, brzi odgovor na njihove potrebe i proizvodnju proizvoda koji su prilagođeni ukusu pojedinca

Izvor: Boban, M. & Babić, A., 2014. Utjecaj internetskih tehnologija na gospodarski rast, poslovni rezultat i stopu rasta profita poduzeća u Republici Hrvatskoj. *Zbornik radova Veleučilišta u Šibeniku,* 1(1-2), str. 65.

Informacijska tehnologija prožima sve segmente poslovanja i općenito svakodnevnog življenja, na što je posebice utjecala decentralizacija infrastrukture i programske podrške – softvera, a da se pri tome nije provodila odgovarajuća zaštita računala i elektroničkih podataka, a postojeća regulativa koja se primjenjivala u glavnim računalnim središnjicama nije se redovno ažurirala.

1.8.2 Određivanje uloge informatike u poslovanju

Kao i svaki način upravljanja, tako i upravljanje informatikom i informacijskim sustavima u poslovanju ima svoja pravila korištenja, koja predstavljaju prvi korak kojeg korisnici (menadžeri) moraju utvrditi. Kada se razmatra problematika informatičke zrelosti u poslovanju Bosilj Vukušić i Pejić Bach (2012, str. 241) navode naredne tri razine („vala“):

- informatiku kao tehnološkog partnera („tehnološki sluga“)
- informatiku kao „procesnog“ i „servisnog“ partnera
- informatiku kao strateškog partnera i stratešku poslovnu funkciju.

U prošlosti se informatika u poslovanju uglavnom koristila kao „tehnološka usluga“, odnosno kao nužna tehnološka infrastruktura poslovanja. Gledajući s vremenske distance, takvu je ulogu na razvijenim tržištima informatika imala sredinom prošlog stoljeća (početkom korištenja računala u poslovne svrhe smatra se 1951. godina kada se računalo UNIVAC I koristio za obradu podataka popisa stanovništva SAD-a). U tom se razdoblju užurbano razvijaju poslovne aplikacije (obračun plaća, računovodstvo, planiranje proizvodnje, skladište, narudžbe itd.), koje automatiziraju račune, postupke obrade, ubrzavaju uvođenje poslovnih procesa i u velikoj mjeri smanjuju troškove. Osnovna funkcija računala bila je računanje, a glavni korisnici bili su profesionalni informatičari.

Obrada podataka provodila se u centraliziranim organizacijskim jedinicama koje su se najčešće nazivale elektronički računski centar (akronim ERC) ili centar za automatsku obradu podataka (akronim AOP, CAOP). Zbog centralizacije načina njihova rada, oni postaju centri moći, korisnicima dijele oskudne informacijske resurse, a često se javljaju i razni problemi (razvoj poslovnih aplikacija dugo traje, rješenja brzo zastarijevaju, postoje problemi pohrane podataka zbog skupog memorijskog prostora itd.). Ipak, s vremenom se razne poslovne aplikacije povezuju u informacijske sustave (60-e godine prošlog stoljeća), javljaju se složenije vrste informacijskih sustava, a pojava i ubrzo masovna uporaba osobnih računala i relacijskih baza podataka (80-e godine prošlog stoljeća) označile su početak korisničkog računarstva (engl. *End-User Computing*), kojim većina djelatnika poduzeća, a ne isključivo stručnjaci – informatičari, počinju upotrebljavati informacijsku tehnologiju u obavljanju svojega posla.

Početkom, a osobito sredinom 80-ih godina prošloga stoljeća intenzivno se povezuju interni poslovni procesi (tzv. tehnološke oaze) pa informacijska i komunikacijska tehnologija postupno počinje služiti kao sredstvo internog povezivanja poslovanja. Taj dugi „val“ uporabe informatike u poslovanju prije svega se odnosi na potporu odvijanja ključnim poslovnim procesima i pružanju usluga primjerene razine kvalitete. Budući da se ključni poslovni procesi svakodnevno odvijaju posredstvom informacijske infrastrukture, očekuje se njezino pouzdano, kontinuirano funkcioniranje uz odgovarajuću razinu dostupnosti i kvalitete. Stoga informatička tehnologija postaje važno sredstvo bitne (radikalne) promjene ili postupnog unaprjeđenja poslovnih procesa, ali i nezaobilazni procesni i servisni partner u poslovanju. Osim formalne uloge, mijenja se i naziv organizacijske jedinice koja upravlja radom informatike. U ovoj fazi to je najčešće odjel (služba) za informatiku, centar za informatiku, a njegov ustroj postaje sve složeniji.

Informacijske i komunikacijske tehnologije sve se više inkorporiraju u postojeće proizvode, kreiraju nove potrebe i usluge, a njihova uporaba i učinkovito upravljanje postaje ključnim pitanjima funkcioniranja i razvoja. Treći se val korištenja informatike u poslovanju pojavljuje krajem 90-ih godina dvadesetog stoljeća i početkom dvadeset i prvog, a determiniran je prvenstveno primjenom informatike i informacijskih sustava kao „strateškog partnera u poslovanju“, odnosno poslovne funkcije čija učinkovita i dosljedna primjena može poboljšati poslovne rezultate i odraziti se na manje troškove, rast, povezivanje poslovanja s okolinom, bolja konkurentska pozicija, promjene načina poslovanja, strateška promjena poslovnih procesa itd.. Informatika zauzima sve više mjesta u organizacijskoj hijerarhiji poduzeća, a time i funkcija glavnog informatičkog menadžera (CIO, engl. *Chief Information Office*, direktor informatike) pripada najvišem stupnju menadžmenta.

1.8.3 Vrednovanje IT-ja u poslovanju

Vrijednost IT-ja nekog poduzeća ne može se izraziti u novčanim jedinicama s obzirom na to da je ona sadržaj svakog poslovnog procesa pri stvaranju proizvoda ili kreiranju usluge. Jednom primijenjena računalna tehnologija postaje sastavni dio poslovanja, koliko zbog olakšanja procesa proizvodnje toliko i zbog očekivanja klijenata (dobavljača i/ili potrošača) poduzeća. To podrazumijeva potrebu za korištenjem IT-ja, ali i praćenje njenog stalnog razvoja.

Kako bi poduzeće koristilo svoje strateške resurse temeljene na znanju i informacijama te kvalitetno njima upravljalo, neophodno je da raspolaže sredstvima i alatima za prikupljanje, analizu i korištenje informacija. Tu do izražaja dolazi računalna tehnologija koja se razvija u pravcu nepogrešivog poslovnog partnera. Kako bi takvo „partnerstvo“ bilo moguće održati potrebno je ulaganje u dizajn, planiranje i upravljanje tim tehnologijama.

Progresivni razvoj informatičke tehnologije rezultira sve složenijim i naprednijim sustavima, koji služe kao poticaj da se informatičke usluge razvijaju i nude u sve kraćim razdobljima. Tržište informatičkih usluga prati tempo razvoja tehnologije, što rezultira širokom ponudom nestandardiziranih usluga koje pak predstavljaju problem informatičkim menadžerima u poduzećima. Naime, većina softverskih rješenja vezana je uz operativne sustave pojedinih proizvođača i nije kompatibilna s drugima. Uz brojnost softverskih usluga, zamjetan je i razvoj informacijske infrastrukture, čime se povećava značaj i problematika upravljanja tim komponentama sustava. Navedena problematika čini upravljanje IT-jem u poduzeću

dinamičnim i kreativnim poslom. Međutim, da bi upravljanje IT-jem bilo pouzdano i da bi moglo odgovoriti potrebama i zahtjevima drugih sastavnica poduzeća i zahtjevima okruženja, mora se sustavno nadograđivati, što povećava njegovu vrijednost, ali i proizvodi trošak za poduzeće. Kako bi upravljanje IT infrastrukturom u nekom hotelskom poduzeću bilo učinkovito, neophodno je uspostaviti kvalitetno planiranje, administraciju i kontrolu kao osnovu za kvalitetno pružanje usluga prema očekivanjima poslovanja. To podrazumijeva, kako navode Melville, Kreamer, i Gurbaxani (2004, str. 63) da se „odgovarajući resursi s pravim vještinama i znanjem koriste na pravi način pri dizajnu i planiranju, isporuci, upravljanju i tehničkoj podršci za infrastrukturu". Isti autori navode razloge zbog kojih je kvalitetno i proaktivno upravljanje informatikom sve važnije (Melville, Kreamer, & Gurbaxani, 2004, str. 64): „1) sve izraženija ovisnost organizacija o informatičkim uslugama, 2) probitačnost informatičkih rješenja za pružanje usluga, 3) informacijska infrastruktura postaje sve veća, 4) kompleksnija i rasprostranjenija, 5) fleksibilnost zbog korisničkih zahtjeva za novim uslugama i promjena poslovnih potreba, 6) zbog utjecaja informatičkih problema na osnovnu poslovnu granu klijenti su sve manje tolerantni na lošu uslugu, 7) postoji zahtjev poslovanja za dokazom vrijednosti investicije u informatiku, informacijska tehnologija mora biti iskorištena kako bi izlazak proizvoda i usluga tvrtke na otvoreno tržište bio u čim kraćem roku, te bi se na taj način stekla kompetitivna prednost".

Nabrojeno ukazuje kako je IT od objekta, odnosno sredstva i alata za pomoć poslovanju, postao subjekt o kojem ovise brojni poslovni procesi. Sve je više očigledno kako je pri poslovnim procesima značajna ovisnost poduzeća o informatičkim i komunikacijskim uslugama. Sukladno tome nastaje i potreba usklađivanja strateških planova temeljnog poslovanja s informatikom. Za kvalitetno i učinkovito upravljanje informatičkom i komunikacijskom tehnologijom neophodno je poduzeti odgovarajuće mjere upravljanja, koje bi uključivale procese, proizvode (usluge) i resurse. Na taj se način može djelovati na troškove informatičke podrške poslovanju, a time i na ukupni trošak vlasništva (engl. *Total Cost of Ownership, TCO*).

Nadalje, upravljanje IT-jem donosi i informacije korisne za upravljanje poduzećem koje bi trebale poslužiti za formiranje poslovnih odluka po pitanjima konkurentnosti i upravljanja troškovima. Vrijednost IT-ja nekog hotelskog poduzeća je mjerljiva samo u području uloženog novca u infrastrukturu, softver, održavanje i upravljanje, što nije upitno, ali ostaje upitno koliki je IT u stvaranju dodane vrijednosti proizvoda i usluga, odnosno kako bi se ta dodana vrijednost ostvarivala da nema podršku informacijske tehnologije.

Jednostavnije je prihvatiti IT kao sveprisutnu, nezaobilaznu i nadasve korisnu pojavu, odnosno simbiozu suvremenom poslovanju.

Saznanja o vrijednosti IT-ja svode se na izračunavanje nastale štete zbog kvarova ili zatajenjima sustava, odnosno kibernetičkim napadima koji se onda izražavaju u velikim novčanim iznosima pa tako Poslovni dnevnik donosi vijest (Poslovni Dnevnik, 2018): „globalni kibernetički napad većih razmjera potencijalno bi mogao izazvati gubitak veći od 50 milijardi dolara, no čak i poludnevni nestanak struje na lokaciji pružatelja *cloud* usluga može uzrokovati štete od oko 850 milijuna dolara“.

1.9 Utjecaj razvoja informacijske tehnologije na hotelsku industriju

Da postoji veliki utjecaj IT-ja na hotelsku industriju i općenito na industriju usluga potvrdila su sva dosadašnja istraživanja i rezultati o kojima je suvišno raspravljati. „Četvrta industrijska revolucija“ stubokom je izmijenila načine poslovanja, poimanje vremena i udaljenosti, brzinu i točnost protoka informacija, bezgotovinskog plaćanja…, ali i većih zahtjeva za kvalitetom usluga, brigom za očuvanjem okoliša i inzistiranja na „vrijednosti za novac“.

Istraživanja o utjecaju IT-ja na hotelsku industriju mogu se podijeliti na dvije vrste izvora, i to one iz relevantnih međunarodnih časopisa koji se bave tom problematikom, poput:

- *Annals of Tourism Research,*
- *Cornell Quarterly,*
- *Information Technology in Tourism,*
- *International Journal of Contemporary Hospitality Management,*
- *International Journal of Hospitality Management,*
- *Journal of Hospitality and Leisure Marketing,*
- *Journal of Travel and Tourism Marketing,*
- *Journal of Travel Research,*
- *Journal of Vacation Marketing,*
- *Tourism and Hospitality Research, Tourism Management,*
- *Tourism Review*.

Zatim i domaći izvori:

- turizam

- *Tourism and hospitality management*
- praktični menadžment te zbornici hrvatskih Veleučilišta i Sveučilišta.

Proučavanjem strane i domaće literature navedene u bibliografskim jedinicama, može se zaključiti kako pri pristupu sagledavanja utjecaja i učinaka IT-ja na turizam općenito, a time i na hotelijerstvo, ne postoje značajne razlike.

Nagli razvoj IT-ja podjednako je zatekao hotelijere u Jordanu (Alshourah, Alassaf, & Altawalbeh, 2018), Indiji (Banga, Kumar, & Goyal, 2013), Pakistanu (Tariq, Jamil, Ahmad, & Ramayah, 2019), Africi (Appiah & Kingsley, 2010), Koreji (Gretzel, Sigala, & Xiang, 2015), Australiji (O'Conor & Murphy, 2004), ali i u turistički i informatički razvijenim područjima, od SAD-a i Meksika do europskih država. Razlika je jedino bila u procesu prilagodbe, savladavanja psiholoških prepreka i otpora ortodoksnih kadrova.

Ipak, kao najznačajniji utjecaj IT-ja na hotelsku industriju potrebno je izdvojiti tri područja koja predstavljaju svojevrstan izazov proučavanja stručnjaka i znanstvenika a odnose se na (O'Conor & Murphy, 2004, str. 475): 1) elektroničku distribuciju, 2) cijene i 3) odnose s gostima.

STRATEŠKI MENADŽMENT HOTELSKOG PODUZEĆA KAO POLUGA IZVRSNOSTI POSLOVANJA

Strateško upravljanje hotelskim poduzećima višekratno je elaborirano u dostupnoj domaćoj i stranoj literaturi te je zahvalna tema za brojne završne, diplomske, stručne i znanstvene radove. Kako bi se izbjegla interpretiranja poznatih stajališta, u ovom se dijelu rada naglasak strateškog menadžmenta usmjerava ka dostizanju poslovne izvrsnosti u hotelskoj industriji. Kako bi se na sustavan način elaborirala problematika strateškog upravljanja hotelskim poduzećem, u ovom dijelu rada analiziraju se: 1) važnija obilježja hotelskog poduzeća kao poslovnog sustava i 2) strateški menadžment u hotelskom poduzeću.

1.10 Važnija obilježja hotelskog poduzeća kao poslovnog sustava

Hotelska je industrija širi pojam koji obuhvaća brojne djelatnosti vezane uz poslovanje nekog hotelskog poduzeća kao temeljne jedinice na kojoj se zasniva cijela industrija. Naime, antropološke značajke posjetitelja, bilo da se radi o domaćem putniku ili stranom turistu, nalažu potrebu za mjestom za odmor, spavanjem, prehranom i pićem. Hotel objedinjuje te osnovne potrebe, a sve dodatno zavisi o kupovnoj moći posjetitelja i marketinškoj sposobnosti destinacije. Hayes i Ninemeier (*Upravljanje hotelskim poslovanjem*, 2005, str. 47), kao segmente hotelske industrije navode: 1) hotelijerstvo i ugostiteljstvo, 2) prodaju na malo, 3) usluge prijevoza i 4) destinacijske aktivnosti.

Cerović (*Hotelski maenadžment*, 2010), izbjegava pojam industrije i naglasak stavlja na hotelijerstvo kao gospodarsku granu. Isti autor nadalje smatra kako „hotelijerstvo, kao gospodarska djelatnost, potiče, omogućava, ali i stvara razvoj odmarališnog, kongresnog, zdravstvenog, vjerskog, te ostalih oblika turizama, bez obzira bili turisti domaći ili inozemni“ (Cerović, 2010).

Hotelijerstvo, u općoj društvenoj djelatnosti, razvrstava se u tercijarne djelatnosti, glede toga što je to gospodarska djelatnost gdje se turistima pružaju usluge smještaja i druge usluge na hotelijerski način, u vrijeme njihova privremenog boravka u smještajnom objektu, ali se mogu pružati usluge i domicilnom stanovništvu, poglavito usluge prehrane i pića te ostale usluge koje nudi hotelski objekt i njegovi sadržaji.

Hotelsko poduzeće poslovni je subjekt koji je nukleus hotelijerstva, a time i hotelske industrije. Čini ga jedan ili više strukturno i organizacijski povezanih hotelskih objekata koji nude usluge smještaja i ostalih usluga na hotelijerski način, kao i posebnih roba i usluga koje se prodaju turistima i lokalnom stanovništvu te se tako ostvaruje turistička potrošnja. U tom smislu, kako navodi Cerović, „realiziraju se i razni hotelski programi koji mogu biti osnovni motiv posjeta ili dodatak hotelske usluge kako bi se potaknuo da boravak bude ugodniji, sadržajniji i po mogućnosti čim duži“ (*Hotelski maenadžment*, 2010, str. 68).

1.10.1 Okolina hotelskog poduzeća

Okolinu hotelskog poduzeća čini njegovo bliže i šire okruženje. Hotelski poslovni sustav nije izolirana jedinka i ne može funkcionirati bez prijateljski naklonjenog okruženja. Naglasak je na prijateljskom okruženju (engl. *Friendly Environment*) s obzirom na to da je teško zamislivo poslovanje u okruženju koje ne prihvaća ono što hotelsko poslovanje zahtijeva. Pored osnovnih infrastrukturnih i logističkih potreba od kojih bi lokana zajednica trebala imati određene koristi, hotel neizostavno utječe na lokalno stanovništvo i okoliš, što iziskuje pažljivo planiranje i prilagođavanje. Šire okruženje predstavlja regija i država koja propisima i zakonima nameće pravila ponašanja i poslovanja.

Do početka novog milenija većina lokalnih zajednica, u turistički manje razvijenim područjima, prizivala je izgradnju hotela smatrajući ih generatorima razvoja i blagostanja. Porastom svijesti o potrebama očuvanja okoliša i prihvaćanjem agende o održivom razvoju, mijenjaju se i stavovi o širenju hotelske industrije, postrožuju se propisi održivog razvoja, uvode ekološke rente, traži se korištenje energije iz obnovljivih izvora i sl.

Međutim globalno okruženje pokazuje trendove rasta turističkih putovanja, raste i broj poslovnih sastanaka, kongresa, sportskih i zabavnih manifestacija, što iziskuje gradnju novih smještajnih kapaciteta, prvo u atraktivnim, a potom i manje atraktivnim turističkim destinacijama.

Iz navedenog proizlazi da će u budućnosti utjecaj okoline imati sve veći učinak na hotelsko poslovanje.

1.10.2 Organizacijska struktura hotelskog poduzeća

Organizacijska struktura hotelskog poduzeća desetljećima je bila percipirana kao stalna, klasična funkcionalna struktura izrađena prema osnovnim potrebama gosta korisnika. Recepcija, restoran, sobe, servis, zabava i marketing funkcije su koje su činile temelj poslovanja do pojave i naglog razvoja informacijsko-komunikacijske tehnologije. S njom se pojavila potreba za informatizacijom doslovno svega što postoji u hotelu. Od elektroničke obrade podataka, sustava rezervacija, načina nabave i prodaje do upravljanja potrošnjom energije, rasvjetom u sobama i elektroničkim bravama. Hotelska poduzeća kao da su se takmičila koja će sve inovativna rješenja bazirana na ICT-ju primijeniti.

Naravno da je to iziskivalo da se u strukturi poduzeća oformi odjel ili služba koja je zadužena za uvođenje, primjenu i održavanje informatike. Razvojem informatike raste i potreba za sve stručnijim i osposobljenijim informatičarima, koji će znati odabrati odgovarajuću aplikaciju po potrebi hotela. Paralelno s time i služba informatike napreduje u hijerarhijskoj strukturi hotelskog poduzeća da bi formiranjem kontrolinga ušla u sam vrh upravljanja hotelskim poduzećem. I služba marketinga je evoluirala u e-marketing, a uvođenjem CRM-a postaje ključna za upravljanje odnosima s gostima.

Međutim složenost organizacijske strukture, fragmentacija cjeline i dijelova, heterogenost funkcija i način organiziranja hotelskog poduzeća nepovoljno utječe na kvalitetu upravljanja. U praksi se uočava nedovoljno korištenje informatičkog sustava (unatoč posjedovanju suvremene informacijske tehnologije), koji je raslojen prema odjelima. No promjene koje dolaze iz okruženja i koje donose gosti sve više stimuliraju menadžment hotela da prilagodi organizacijske strategije informatičkim dostignućima, sa svrhom unaprjeđenja strateškog upravljanja. Usuglašenost strategije i organizacijske strukture pretpostavka je smislene reakcije hotelskog poduzeća na promjene traženja povoljnije strateške pozicije. U tom je kontekstu poželjna prilagodljiva organizacijska struktura koja će omogućiti provođenje strategije.

Organizacijska struktura hotelskog poduzeća predstavlja dimenziju specifičnih sposobnosti upravljanja i kao takva utječe na efikasnost i efektivnost poslovanja. Ona čini sustav veza i odnosa između elemenata u organizaciji, a može poprimati različite oblike. Osnovni oblici su funkcionalna i divizijska organizacija, iz kojih evoluiraju brojni modificirani i inovativni modeli sukladno vrsti hotela, kriterija koje treba zadovoljiti i području u kojem djeluje. Teoretičari hotelskog menadžmenta Meson, Alber, i Khedouri (*Management*, 1985, str. 669) smatraju kako je osmišljavanje organizacijske strukture jedna od najbitnijih odluka jer pogrešno

dizajnirana struktura može dovesti do disfunkcije upravljačkog sustava. Nadalje, oni smatraju kako najveći utjecaj na formiranje organizacijske strukture imaju:

1) unutarnji čimbenici – ciljevi, zadatci i strategija, veličina i namjena hotela, tehnologija, ljudski resursi
2) vanjski čimbenici – društveni, politički, ekološki, konkurencija.

Navedeni čimbenici ponekad imaju i sinergijski učinak, a ponekad su suprotnog predznaka, što u najvećoj mjeri zavisi od okruženja s obzirom na to da je hotel klasično poduzeće.

1.10.3 Organizacija poslovnih i procesnih funkcija u hotelskom poduzeću

Pod organizacijom poslovanja u hotelskom poduzeću podrazumijeva se 1) organizacijska struktura hotela koja je definirana horizontalno i vertikalno i 2) vremenski definirana organizacija odvijanja poslovanja po svim hotelskim odjelima i radnim mjestima. Organizacija stvara osnove za optimalno funkcioniranje i međusobnu povezanost svih odjela koji su u hotelu potrebni, odnosno stvara podlogu za donošenje utemeljenih poslovnih odluka.

Kakva se vrsta organizacijske strukture u pojedinom hotelskom objektu primjenjuje, ovisi o: „1) veličini, vrsti i tipu hotela, 2) kategoriji hotela i standardu kvalitete usluge te 3) vrsti gradnje hotela (stari objekt – tradicionalni način gradnje ili novogradnja)“ (Cetinski, 2005, str. 108).

Neovisno o navedenom, svaki pojedini hotelski odjel mora biti inkorporiran u organizacijsku strukturu hotela kako bi se omogućilo nesmetano pružanje usluga i usklađeno zajedničko funkcioniranje svih hotelskih odjela. Temeljni odjeli koji čine i određuju hotel su:

- odjel smještaja, koji uključuje recepciju i domaćinstvo
- odjel hrane i pića, koji uključuje kuhinje, restorane, šankove i ostale potrošne punktove hrane i pića
- održavanje
- uprava hotela.

Svi ostali mogući odjeli pojavljuju se u pojedinim vrstama hotela ovisno o dodatnim sadržajima i njihovoj brojnosti. Tako pojedini hoteli imaju odjel sporta i rekreacije, odjel provođenja slobodnog vremena (s mnoštvom manjih zabavnih sadržaja), odjel trgovine i slično.

Administrativni poslovi od zajedničkog interesa za cijeli hotel (marketing, prodaja, računovodstvo i financije, kadrovski i opći poslovi) mogu biti organizirani bilo u hotelu (to je

najčešće u slučaju hotela-poduzeća), bilo kao središnje službe u poduzeću (u slučaju velikih višeodjelnih poduzeća konglomeratskog tipa), ili pak povjereni drugim poduzećima (angažiranje drugih poduzeća za obavljanje pojedinih poslova – marketinške usluge, računovodstvene usluge i slično).

1.11 Razine i funkcije menadžmenta u hotelskom poduzeću

Funkcije menadžmenta ostvaruju menadžeri koji se uobičajeno nazivaju „direktori, upravitelji, rukovoditelji ili ravnatelji“ (Zelenika & Pupavac, 2008, str. 125). Oni kreiraju model upravljanja koji će, prema njihovu poimanju, poduzeću donijeti najbolje poslovne rezultate. Da bi u tome uspjeli, model upravljanja trebao bi se temeljiti na pozitivnim međuljudskim odnosnima, kvalitetnoj komunikaciji, timskom rukovođenju te sustavima stimulativnog nagrađivanja rada. Menadžeri u svojim odnosima komuniciraju sa zaposlenicima. Upravljanje bi stoga kao međuljudski odnos trebalo biti partnerski odnos zaposlenika i rukovoditelja.

Kreiranje, dizajniranje, operacionaliziranije, upravljanje, servisiranje, kontroliranje misijama, kapacitetima, resursima u globalnim, mega, makro te mikroindustrijama i poduzećima nezamislivo je bez menadžmenta. Od brojnih definicija menadžmenta izdvaja se ova: „menadžment je proces rada s drugima i pomoću drugih na ostvarivanju ciljeva poduzeća u promjenjivom okruženju, uz efektivnu i efikasnu uporabu ograničenih resursa (Zelenika & Pupavac, 2008, str. 126)“.

1.11.1 Zahtjevi i ciljevi pred menedžmentom u hotelu

Zahtjevi koji se postavljaju pred menadžerima su kompleksni, stoga menadžer treba „ovladati brojnim znanjima i vještinama kako bi osigurao ostvarivanje planiranih poslovnih ciljeva u hotelskom poduzeću“. Tada se posebno naglašava važnost poznavanja tržišta i primjena marketinških spoznaja i vještina. Opća znanja uključuju i dobro poznavanje izvora financiranja, upravljanja financijama, kontroliranje troškova, upravljanje kvalitetom i očuvanjem okoliša kao preduvjetima pozicioniranja na turističkom tržištu, što su ujedno i ciljevi uspješnog menadžmenta.

Od menadžera se nadalje očekuje da poznaje operativno i strateško planiranje te vještinu izrade poslovnih planova i, što je najvažnije, njihovu uspješnu primjenu. Kada se radi o većem hotelskom poduzeću, tada menadžer ostvaruje svoje ciljeve angažiranjem drugih da izvrše zadatke (Buble, 2006, str. 42).

Osnovne uloge menadžera, kako ih prema Mintzbergu sistematizira Pfeifer (*Menadžment,* 2006, str. 11), predstavljene su narednim prikazom.

Slika 5. Uloge menadžera po Mintzbergu

Kategorija	Uloga	Aktivnost
Informacijska	Osoba za nadzor Prenositelj informacija Glasnogovornik	Traži, prima izvještava djelatnike, oblikuje informacije za van
Interpersonalna	Reprezentant Vođa Osoba za veze	Predstavlja poduzeća, Usmjerava, obučava, Održava komunikaciju
Uloga odlučivanja	Poduzetnik Korektor Alokator resursa Pregovarač	Inducira ideje, Rješava konflikte, Odobrava budžet, Predstavlja interese poduzeća

Izvor: prema Pfeifer, *Menadžment*, 2006. p. 7.

Prema Mintzbergu postoje tri osnovne kategorije menadžerskih uloga, a to su informacijska, interpersonalna i uloga odlučivanja, koje potom razvrstava u deset uloga s opisom njihovih aktivnosti. Svi stupnjevi menadžmenta neovisno o hijerarhiji primjenjuju sve tri kategorije uloga. Primjerice interpersonalnim ulogama menadžeri uspostavljaju kontakte kojima zaprimaju informacije, što potvrđuje potrebu da menadžer pored spleta znanja i vještina mora posjedovati i određeni talent i afinitet prema međuljudskim odnosima.

Stoga je važno da postoji i adekvatan sustav selekcije koji će izabrati menadžera od mogućih ponuđenih na tržištu kadrova, koji će na određenoj razini menadžmenta polučiti najbolji efekt.

Hotelski menadžer mora posjedovati specifične osobine koje se razlikuju od osobina menadžera iz drugih gospodarskih grana. On prije svega mora znati komunicirati sa gostima, ali i cjelokupnim osobljem hotela te mora objediniti razlike zahtjeva gostiju, njihove različite motive i navike, i na taj način organizirati hotelski proizvod kojim su zadovoljni svi ili većina posjetitelja. Menadžer kojem to uspije može se nazvati efikasnim.

U hotelijerstvu se stvara, nudi i realizira usluga čija se kvaliteta povezuje s kvalitetom rada zaposlenika, a koja je određena znanjima i vještinama iz područja ugostiteljstva i hotelijerstva općom kulturom i bontonom te tehnološkim znanjima i vještinama. Ljudski potencijal temelj je uspjeha svakog poduzeća, a u turizmu kao pretežno uslužnoj djelatnosti zaposlenici su čimbenici ostvarenja konkurentske prednosti. Kvaliteta turističkog proizvoda ovisi o nizu faktora, kako vanjskih tako i unutrašnjih, a ljudski potencijal valja promatrati kao glavni čimbenik utjecaja na kvalitetu proizvoda hotelske industrije.

1.11.2 Menadžerski podsustavi

Prema Kast i Rosenzwweigh (*Organization and management - a system approach*, 1979, str. 12), uočavaju se tri temeljna podsustava menadžmenta povezana s različitim razinama složenosti organizacijske strukture i to: „1) operativni podsustav, 2) koordinacijski podsustav i 3) strategijski podsustav". Navedeni podsustavi korespondiraju s različitim razinama menadžmenta.

Menadžerski podsustavi i razine su međusobno povezani i isprepleteni, i ne mogu se precizno diferencirati, posebice u manjim hotelima ili hotelskim poduzećima. Pristup promatranju menadžmenta kroz niz međusobno povezanih podsustava dovodi u pitanje postojanje neke linije autoriteta i čvrste hijerarhijske osnove od vrha do dna poduzeća. Različite razine menadžmenta, kao i menadžeri na tim razinama, imaju različite uloge, stoga Radišić (*Poduzetnički menedžment u turizmu*, 1997, str. 187) smatra da se „prema kriteriju raspona odgovornosti na pojedinim organizacijskim razinama u hotelu, menadžment može podijeliti na tri razine (vrhovni, srednji i niži)".

Menadžment najviše razine u većini hotela sadržan je u jednoj osobi – glavnom direktoru hotela (engl. *General Manager*), dok je u manjem broju hotela (općenito u Hrvatskoj), u menadžment najviše razine ubrojeno i još nekoliko osoba koje obavljaju odgovorne poslove, kao npr. izvršni direktor hotela, direktor prodaje, šef recepcije, direktor hrane i pića, direktor banketnog odjela, direktor kongresnog odjela i sl.

Menadžment najviše razine, neovisno o broju ljudi koji mu pripadaju, ima ovlasti i odgovornosti za poslovanje cijelog hotela, a može ovlastiti pojedine suradnike za upravljanje pojedinim područjima poslovanja. Menadžeri s takvim ovlastima nazivaju se funkcionalnim

menadžerima jer odgovaraju glavnom menadžeru za pojedine funkcije, npr. direktor nabave, direktor prodaje, kadrovski direktor i sl.

Odluke su menadžmenta najviše razine u odnosu na druge razine menadžmenta u hotelu malobrojne, ali vrlo kompleksne po svojem sadržaju. Jedan je od najvažnijih zadataka menadžmenta najviše razine postavljanje ciljeva organizacije, stalna uključenost u formuliranje strategije poslovanja i posjedovanje strateške vizije za svaki posao.

Ključni zadatci menadžmenta najviše razine su: „oblikovanje radne okoline, postavljanje strategije poslovanja hotela, raspoređivanje sredstava (alokacije resursa), razvoj menadžera na nižim razinama u organizaciji (obučavanje), izgradnja organizacije i nadgledanje poslovanja“ *(*Galičić & Šimunčić*, Informacijski sustavi i elektroničko poslovanje u turizmu*, 2006, str. 70).

Menadžeri u hotelskom poduzeću koriste različite vještine da bi obavili svoje temeljne funkcije, i to u svim vrstama hotela bez razlike (velikim – malim, sezonskim – cjelogodišnjim, urbanim, kontinentalnim, priobalnim ili otočnim), s obzirom na to da svi menadžerski poslovi nisu istovjetni te da su različiti menadžeri odgovorni za raznovrsna područja rada i da su njihove pozicije na različitim stupnjevima organizacijske hijerarhije. Neovisno o tome što svi menadžeri ostvaruju jednake funkcije, opseg svake od tih funkcija različito se odražava kod različitih razina i funkcijskih područja menadžmenta te se i odražava na razne načine.

U tom se kontekstu razlikuju oblici menadžmenta promatrani sa stajališta razine, djelokruga odgovornosti i tipa menadžmenta. Bitna je odrednica definiranja menadžerskog posla njegova uloga koju zauzima u organizacijskoj hijerarhiji. U tom je kontekstu moguće analizirati vertikalnu diferencijaciju menadžera. Promatrano s aspekta hijerarhije, uobičajeno se razmatraju tri osnovne razine menadžmenta, a to su:

1. vrhovni menadžment ili menadžeri na najvišoj razini
2. srednji menadžment ili menadžeri na srednjoj razini
3. niži menadžment ili menadžeri na prvoj razini.

Vrhovni menadžment (engl. *Top Management*) čine menadžeri na najvišoj hijerarhijskoj razini i oni su odgovorni za hotelsko poduzeće kao cjelinu. Nazivaju se direktor hotela, izvršni direktor, CEO *(Chief Executive Officer*). Temeljna se odgovornost ovih menadžera ogleda u sljedećem:

- osmišljavanje i određivanje ciljeva poslovanja
- određivanje strategije i donošenje strateških odluka za ostvarenje postavljenih ciljeva
- nadzor i tumačenje pojava iz eksterne okoline

- osmišljavanje, donošenje i provođenje odluka koje utječu na hotelsko poduzeće kao cjelinu.

Sve su navedene odgovornosti vrhovnog menadžmenta usmjerene ka budućem poslovanju hotelskog poduzeća. Iz toga se podrazumijevaju i brojne menadžerove aktivnosti, a koje se odnose na komuniciranje zajedničke vizije, oblikovanje korporacijske kulture i njegovanje poduzetničkog duha kao pokretača ideja i inovacija potrebnih za očuvanje i unaprjeđenje konkurentske pozicije na tržištu hotelijerskih usluga.

Stoga je i zadaća vrhovnog menadžmenta da angažira sve resurse i potakne znanje, vještine i sposobnosti svakog hotelskog djelatnika.

Srednji menadžment čine menadžeri odgovorni za funkcioniranje svih poslovnih jedinica i pratećih službi u jednom hotelskom poduzeću. O njihovom angažmanu, sposobnostima i lojalnosti poduzeću ovisi učinak provođenja strategije i zacrtanih ciljeva koje postavlja vrhovni menadžment. Primjerice, u hotelskom poduzeću hijerarhijsku poziciju srednjeg menadžera zauzimaju šef recepcije, šefovi odjela, šefovi sektora, rukovoditelji službe razvoja, rukovoditelji financije itd. Srednji menadžeri orijentirani su na bližu budućnost te se od njih očekuje da uspostave dobre odnose s relevantnom okolinom hotela, potiču timski rad i rješavaju konfliktne situacije.

U hotelskoj industriji postoje trendovi reduciranja srednjeg menadžmenta sa svrhom uspostavljanja *lean*-poduzeća u kojima su protokoli i procedure u velikoj mjeri prihvaćene od zaposlenika te time prestaje potreba za srednjom razinom upravljanja. Problem takvog sustava nastupa kada se uvode novi proizvodi i usluge te kada se ukazuje potreba za koordinaciju poslova, što se rješava uvođenjem projektnog menadžmenta, koji ima svoj rok izvršenja.

Projektni menadžer odgovoran je za izvršenje projektnog zadatka. U svojem poslu je samostalan s velikim ovlastima, ali i s velikom odgovornošću za uspješni dovršetak projekta. Očekuje se da srednja i niža razina menadžmenta budu u cijelosti kooperativne i posvećene uspjehu projekta.

Niži menadžeri neposredno su odgovorni za proizvodnju hotelske usluge. Njihov je osnovni zadatak nadgledanje, korigiranje i ispitivanje izvršenja hotelskih usluga, od pripreme hrane do portirske službe. Orijentirani su na dnevne zadatke s naglaskom na poštivanje pravila i procedura za ostvarenje kvalitetne proizvodnje, osiguranje tehničke podrške i motiviranje zaposlenika.

1.12 Strateški menadžment u hotelskom poduzeću

Strateško upravljanje u hotelskom poduzeću valja analizirati u kontekstu strateškog upravljanja u uslužnim poduzećima općenito. Naime, hotelijerstvo je djelatnost koja se temelji na usluzi koja iziskuje velik udio ljudskoga rada, o čijoj stručnosti i angažiranosti ovisi kvaliteta usluge. Strateško upravljanje hotelskim poduzećem razlikuje se od strateškog upravljanja u drugim gospodarskim sektorima, čiji su proizvodi mjerljivi, opipljivi i uskladištivi, stoga je kod oblikovanja modela strateškog upravljanja potrebno, kako navodi Cetinski (*Strateško upravljanje razvojem turizma i organizacijska dinamika*, 2005, str. 20) poznavati i razumjeti „narav i razmjer ulaganja potrebnih za razvoj djelatnosti, prirodu i vrstu ljudskih resursa neophodnih za određenu djelatnost (imajući na umu ulogu ljudskoga faktora u uslužnim djelatnostima), prirodu tržišta na kojima se usluge nude, procese uspostavljanja prioriteta i mogućih supstituta usluga koje se nude, specifične ograničavajuće faktore u određenoj djelatnosti, učinak 'novoga proizvoda' i njegov utjecaj na razinu konkurentnosti nuditelja usluga te saznanja o nepostojanju cjelokupne prevlasti neke uslužne djelatnosti na dugi ili srednji rok“.

Iz navedenoga proizlazi kako nije moguće oblikovati jedinstven obrazac strateškog upravljanja hotelskim poduzećem, nego je potrebno slijediti posebnosti svake od usluga koje se proizvode, odnosno razumijevati opće i posebne značajke hotelijerstva u oblikovanju ponude turističkoga sektora u destinaciji.

Cilj je strateški usmjerenog hotelskog poduzeća odrediti i primijeniti strategije koje će rezultirati stvaranjem dodane vrijednosti i ostvarenjem konkurentske prednosti. Stoga je svrha strateškog menadžmenta da usmjeri sve aktivnosti poslovanja za dostizanje postavljenih ciljeva.

1.12.1 Posebnosti strateškog menadžmenta u hotelijerstvu

Menadžment u hotelijerstvu Pavia (2004, str. 127) definira kao „sustav stvaranja, usmjeravanja i usklađivanja svih faktora koji utječu na oblikovanje hotelske ponude“. Osnovni je cilj hotelskog menadžmenta ostvarenje što većih poslovno-financijskih rezultata uz što niže troškove.

Dugogodišnje proučavanje menadžmenta u hotelskoj industriji iznjedrilo je i brojne teorijske klasifikacije menadžerskih funkcija. Uglavnom se većina autora slaže oko bitnih menadžerskih

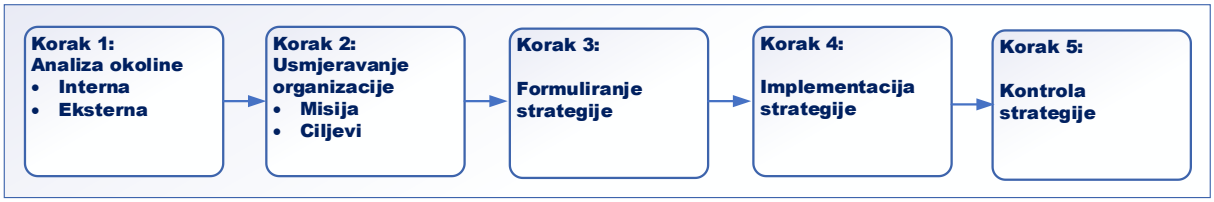
funkcija, a to su: 1) planiranje, 2) organiziranje, 3) motiviranje 4) vođenje, 5) kontroliranje i 6) upravljanje ljudskim potencijalima.

Vršiti funkciju hotelskog menadžera razlikuje se od obavljanja menadžerske funkcije u bilo kojoj drugoj gospodarskog djelatnosti. Za razliku od „običnog“ menadžera, hotelski menadžer mora posjedovati izuzetno važnu vještinu i sposobnost komuniciranja s gostima jer bez gostiju hotel ne bi postojao, ali isto tako mora znati odabrati i motivirati kvalitetno osoblje s kojim će, kroz vještinu komunikacije, pridonijeti zadovoljstvu gosta. Budući da gosti imaju različite potrebe, navike i motive te dolaze iz različitih kulturnih i društvenih okruženja, zadatak je uspješnog menadžera da u suradnji s cjelokupnim osobljem hotela pruži gostu hotelski proizvod koji će ga zadovoljiti.

Upravljanje hotelskim poduzećem ima svoje specifičnosti koje proizlaze iz hotelskog bližeg i šireg okruženja. Stoga se iz mnoštva definicija menadžmenta izdvaja Kreitnerova (*Management*, 1993, str. 8), koja pod upravljanjem podrazumijeva „proces kojim se uz učinkovitu uporabu resursa i uvjetima nepredvidljivog okruženja ostvaruju zadani ciljevi“. Sukladno tome, strateški je menadžment vještina upravljanja hotelskim poduzećem provođenjem strateških planova sa svrhom dostizanja strateških ciljeva.

Sam pojam strategije upućuje na borbu (natjecanje) s protivnicima (konkurencijom) na bojnom polju (nepredvidljivom okruženju) koja od vođe (menadžera) iziskuje vještinu ratovanja i osobnu žrtvu. Aluzija na ratna zbivanja samo je preslika stvarnog natjecanja na slobodnom tržištu uvjetima nesmiljene konkurencije. Uspješan će menadžer proces strateškog upravljanja sagledavati kao neprekidni iterativni proces koji uključuje analizu okruženja, misije i ciljeve hotela, formuliranje strategije, implementaciju strategije i kontroliranje (Čerović & Knežević, 2019, str. 161), kako je to predočeno narednom slikom.

Slika 6. Glavni koraci procesa strateškog menadžmenta



Izvor: Certo,S., Peter, P., *Strategic Management, Concepts and Applications*, McGraw-Hill, 1991., str. 11

Sve sastavnice procesa strateškog menadžmenta predstavljaju po svom sadržaju analize čimbenika, pretpostavke budućih kretanja, korištenje odgovarajućih alata i tehnika te veliku

složenost koja iziskuje lucidnost i inovativnost vrhovnog menadžmenta, odnosno tima za provođenje strategije.

Strategija je temeljna poslovna odluka kojom se određuju modaliteti za dostizanje ciljeva i koja diktira smjer poslovanja. Formuliranje strategije složen je proces koji zahtijeva poznavanje misije i ciljeva poduzeća te izrade strateških planova.

Pored navedenih razina i funkcija menadžmenta neophodno je pozicionirati hotelsko poduzeće u odnosu na industriju i potencijalne klijente. Što je brži tehnološki razvoj, to je brži tempo promjene – što posebno vrijedi za hotelsko poslovanje. Utjecaj vanjskih promjena na poslovanje je značajan pa čak i manji probici ili skromniji razvoj mogu ostaviti uvećane učinke.

Pa iako je nemoguće uzeti u obzir svaku moguću promjenu ili čimbenike koji mogu negativnom utjecati na poslovanje, ipak postoje načini za predviđanje mogućih promjena i preventivne prilagodbe poslovnih operacija kako bi se ili iskoristile ove promjene, ili barem umanjio njihov štetan utjecaj. Prema Mateši (*Uvod u strateški menadžment*, 2019, str. 80) četiri su stupa koja nose promjenu, i to: 1) informacije, 2) predviđanje, 3) inovacija i 4) reakcija.

Prvi stup nužan za oblikovanje uspješne poslovne strategije je ***informacija***. Kvalitetna je informacija ona koja ima kontekst i koja bi mogla utjecati na svakodnevne poslovne operacije, kao i na buduće prilike za uspjeh. Informacija od važnosti ona je informacija koja pomaže boljem razumijevanju hotelske industrije, turističkog tržišta, gostiju, kao i širem okruženju u kojem hotelsko poduzeće posluje. Informacija mora biti dostupna svima kojima je potrebna za donošenje odluka jer ako oni kojima trebaju informacije za odlučivanje ne mogu naći te informacije, bit će im teško donositi informirane odluke. Informacija je „najvarijabilnija imovina, koja se stalno mijenja“ (Mateša, 2019, str. 88). Ažurna saznanja o konkurenciji, tržištu i turističkim trendovima najmanje je s čime menadžment treba raspolagati za donošenje informiranih odluka.

Drugi stup koji proizlazi i znanja i informacija je ***predviđanje.*** Povijest se ponavlja[1] i oni menadžeri koji dobro poznaju povijest (hotelske industrije), trebali bi biti u stanju predvidjeti promjene i previranja na tržištu, koja mogu ostaviti negativne ili pozitivne učinke na poslovanje. Naime, kako poručuje Mateša (2019, str. 88), „u svakoj situaciji – čak i onima koje se univerzalno smatraju negativnima – postoji netko tko će se okoristiti.“ Stoga iskorištavanje informacija sa svrhom predviđanja promjena omogućit će menedžmentu da bude u prednosti u odnosu na konkurenciju. Sposobnost predviđanja promjena na tržištu – kao i poslovna

[1] *Historia est magistra vitae*

strategija koja ističe predviđanje i odgovarajuću prilagodbu – omogućit će poslovnom subjektu da ostane fleksibilan, bude ukorak s vremenom i pruži usluge ili proizvode koji se traže.

Treći stup čine ***inovacije.*** One su u uskoj vezi s predviđanjima, a predstavljaju sinonim za prilagodbu koja omogućuje ravnopravno natjecanje s novonastalim tržištima i zadržavanje konkurentnosti i kvalitete. Svako hotelsko poduzeće može izvući korist iz inovacija. Oni koji prihvate „inovacijski duh" kao ključni dio svoje poslovne strategije imaju veće mogućnosti opstati na tržištu. Ipak, inovacija ne bi trebala biti u prednosti u odnosu na kvalitetu usluge. Primjerice, nove metode prijave i odjave za goste, kojim se može ubrzati ovaj proces i izbjeći uobičajene neugodnosti, može polučiti dobre rezultate. Međutim nedostatak osobnog kontakta recepcionar – gost mogao bi rezultirati negativnim učinkom.

Četvrti stup uspješne poslovne strategije je ***reakcija***. Iako reakcija možda nije važna kao predviđanje, činjenica je da ima situacija koje se ne mogu predvidjeti niti očekivati. U tim situacijama nužno je reagirati. Pored toga, sposobnost reagiranja na promjene na tržištu omogućit će hotelskom poduzeću da ostane relevantno, čak i kada gosti traže nešto drugo.

Svaki od ovih stupova ključan je za razumijevanje položaja hotelskog poduzeća na širem tržištu kao preduvjet razvoj prilagodljive poslovne strategije koja će osigurati uspjeh na turbulentnom tržištu. Menadžer u hotelskoj industriji mora prvenstveno poznavati svoj hotel te permanentno prikupljati informacije o okruženju i industriji, kao i biti umješan u predviđanju promjena na tržištu i zbog ponašanja gostiju te vanjskih čimbenika, kao što su politička previranja ili promjene velikih razmjera u životnim stilovima ljudi.

Postoje razdoblja kada je utjecaj vanjskih čimbenika nepredvidiv (politički prevrati, ratni sukobi, vremenske nepogode, prirodne katastrofe...), ali uglavnom postoje razdoblja kada se uz ispravne projekcije mogu predvidjeti neke od promjena koje će se dogoditi na globalnom turističkom tržištu ili unutar potražnje hotelskih gostiju. Predviđanjem tih promjena mogu se prilagoditi poslovne strategije.

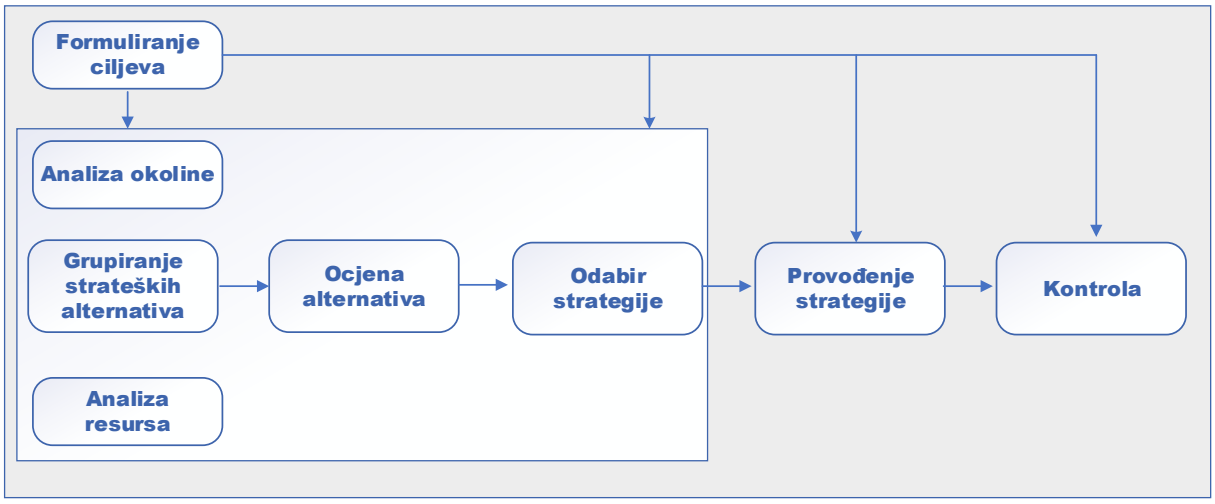
1.12.2 Moguće strategije hotelskih poduzeća

Promatrano s aspekta konkurentske pozicije na tržištu postoje dvije osnovne strateške mogućnosti (Čerović & Knežević, 2019, str. 171):

1. ofenzivne strategije su progresivne i usmjerene ka zauzimanju vodeće konkurentske pozicije ne tržištu od kojih se izdvajaju:
   - strategija stabilnog rasta, koju hotelsko poduzeće koristi kada se nalazi u zadanim okvirima poslovanja
   - strategija usredotočenosti na prepoznati tržišni segment, na kojem je moguće dostići konkurentsku prednost u odnosu na konkurenciju
   - strategija diverzifikacije, koju primjenjuju hotelska poduzeće koja imaju više konkurentnih proizvoda;
2. defanzivne strategije primjenjuju se kod stagnacije ili pada pozicije hotela na tržištu a izdvajaju se:
   - strategija reduciranja troškova, kojom se nastoji prevladati problem likvidnosti
   - strategija deinvestiranja, kojom se odustaje od investicijskih planova i smanjenja obujma poslovanja zbog nerentabilnosti
   - strategija žetve je povlačenje likvidnih sredstava i smanjenja udjela na tržištu
   - strategija stečaja ili likvidacije, kada su izgledi za oporavak poslovanja neznatni te se očekuje neki novi početak.

Koju će strategiju odabrati i u kojem će je trenutku početi primjenjivati odlučit će menadžment na temelju sveobuhvatne analize prikupljenih informacija iz internog i eksternog okruženja i metoda predviđanja (scenariji). Za uslužni sektor kojem hotelijerstvo i turizama pripadaju bitna je orijentacija na gosta (potrošača) koja predstavlja jasan i nedvosmislen cilj. Shematski prikaz dizajniranja strategije predočava se narednom slikom.

Slika 7. Dizajniranje strategije i strateško upravljanje



Izvor: prema Čerović i Knežević, *Menadžment u hotelijerstvu*, 2019., str.169

Strateške odluke se donose u neizvjesnim uvjetima, odnosno u uvjetima nepoznavanja svih relevantnih čimbenika utjecaja. Kako bi se strateške odluke mogle formirati, menadžmentu stoje na raspolaganju brojne metode, a on odabire one koje su najprikladnije trenutku i resursima kojima raspolaže.

1.12.3 Modeli strateškog menadžmenta u hotelskoj industriji

Modeli strateškog menadžmenta predložak su za kreiranje prilagodljivog procesa upravljanja sa svrhom kontroliranja prijetnji iz okruženja i sprječavanju mogućih naglih poremećaja. Naglasak je na usklađivanju svih resursa hotelskog poduzeća s ciljem ostvarenja konkurentskih prednosti na tržištu. Osnovni modeli strateškog menadžmenta prema Druckeru *(Efikasan direktor*, 1992) sistematizirani su u narednom prikazu.

Slika 8. Modeli strateškog menadžmenta

Model	Strategije u hotelskom poduzeću	Dostizanje ciljeva
Upravljanje strateškim funkcijama	➢ Strategija razvoja proizvoda ➢ Strategija penetracije ➢ Strategija razvoja tržišta	Vertikalnom integracijom Pripajanjem, Zajedničkim ulaganjem Franšizom Pristupanjem strateškom savezima Optimizacijom marketing miksa
Portfolio matrice	➢ Rast tržišta/tržišni udjeli	BCG matrica McKinsey / General Electric matrica Matrica politike orjentacije (Shell matrica) ADL matrica (matrica životnog ciklusa)
Višekriterijsko planiranje	➢ Metode scenarija	Što-ako analize
Upravljanje strateškim planovima	➢ Sustavna procedura za rano prepoznavanje prijetnji iz okruženja	Kontinuirano praćenje signala iz okruženja
Upravljanje pomoću ciljeva MBO – (Management By Objectives)	➢ Postavljanje godišnjih ciljeva:	Financijski ciljevi

Izvor: prilagođeno prema Drucker, *Efikasan direktor*, 1992.

Koji će model određeno hotelsko poduzeće odabrati pri definiranju svoje strategije zavisit će o trenutku i okruženju u kojem se strategija donosi te o iskustvu i znanju menadžmenta. Pri tome je bitno uočiti distinkciju između financijskih i strateških ciljeva, kako se to predočava narednim prikazom.

Slika 9. Financijski i strateški ciljevi hotelskog poduzeća

FINANCIJSKI CILJEVI	STRATEŠKI CILJEVI
- Brži rast prihoda	- Veći tržišni udjeli
- Brži rast zarada	- Bolje, sigurnije rangiranje u djelatnosti.
- Veće dividende	- Unapređenje kvalitete proizvoda.
- Veće marže od prodaje hrane i pića	- Niži troškovi u odnosu na kljucne konkurente.
- Veći prihodi po investiranom kapitalu	
- Bolje kreditno rangiranje i rangiranje	- Poboljšanje asortimana proizvoda.
- Veći prilivi gotovine	- Bolja reputacija kod turista.
- Smanjenje troškova poslovanja	- Kvalitetnije pružanje usluga turistima.
- Rast vrijednosti dionica	- Status lidera u tehnologiji i/ili u proizvodnoj inovaciji.
- Raznovrsnija osnova prihoda	
- Stabilne zarade tokom perioda	- Veća konkurentna sposobnost na međunarodnim tržištima.
- Uravnoteženje novčanih tokova	
- Povećanje udjela u kanalima prodaje	- Veće razvojne mogućnosti
- Povećanje turističkog prometa i potrošnje, prosječne dužine boravka i neto prihoda;	
- Uvećanje efekata na osnovu korištenja na temelju povećane promocije	
-Povećanje očekivanih učinaka razvoja i inovacije hotelskog proizvoda i	
- Doprinos istraživanja tržišta poboljšanju kvaliteta proizvoda, potpunijim učincima promocije, povećanju stupnja konkurentnosti, itd.	

Izvor: prema Čerović i Knežević, *Menadžment u hotelijerstvu*, 2019., str.169

U uvjetima slobodnog tržišta i povećane konkurencije na hotelijerkom tržištu odabir i primjena strategije uvelike ovisi i o sustavu odgovarajućeg nagrađivanja. Naime, nagrade i poticaji imaju velik značaj u društvenom smislu, ali sa stajališta vođenja osobno zalaganje i ponašanje menadžmenta mogu predstavljati dodatni poticaj svim djelatnicima za povećani angažman neovisno o nagrađivanju.

1.12.4 Generičke strategije

Kako bi hotelsko poduzeće uspješno ostvarilo svoje tržišno pozicioniranje temeljeno na segmentaciji tržišta i diferencijaciji svojih proizvoda i usluga te prednjačenja u smislu niskih troškova, poželjno je koristiti tri generičke strategije kako ih je opisao Porter (*Competitive Advantage (Creating and sustaining superior performance)*, 1985, str. 11), a to su: 1) strategija troškovnog vodstva, 2) strategija diferencijacije i 3) strategija fokusiranja. Opći uvjeti za primjenu Porterovih generičkih strategija sistematizirani su te se predočavaju:

Slika 10. Opći uvjeti za primjenu Porterovih generičkih strategija

GENERIČKE STRATEGIJE	RESURSI	ZAHTJEVI
Strategija troškovnog vodstva	- Održive investicije i pristup kapitalu - Vještine procesnog inženjeringa - Intenzivni nadzor radne snage - Proizvodi projektirani za lakšu proizvodnju - Sustav distribucije s niskim cijenama	- Jaka kontrola cijena - Česti detaljni izvještaji o kontroli - Strukturna organizacija i odgovornost - Stimulacija na temelju ispunjavanja kvantitativnih ciljeva
Strategija diferencijacije	- Jake marketinške sposobnosti - Proizvodni inženjering - Kreativna pronicljivost - Jaka sposobnost temeljnih istraživanja - Korporativna reputacija - Dugogodišnja tradicija ili jedinstvena kombinacija benchmakinga - Jaka suradnja preko kanala	- Snažna koordinacija između funkcija u R&D, razvoju proizvoda i marketingu - Subjektivno mjerenje i stimulacije umjesto kvantitativnog mjerenja - Prednost pridobivanja školovane i kreativne radne snage
Strategija fokusiranja	-Kombinacija vještina i resursa usmjerenih prema strateškom cilju	- Kombinacija organizacijskih uvjeta orijentiranih prema strateškom cilju

Izvor: prema Porter, *Competitive Advantage (Creating and sustaining superior performance)*, 1985.

U hotelskoj industriji najčešće se u praksi koristi strategija fokusiranja. Semantika obilježja generičkih strategija predočava se narednom tablicom.

Slika 11. Obilježja generičkih strategija

GENERIČKE STRATEGIJE	
Strategija troškovnog vodstva	➢ Naglasak na proizvodnji - "naš hotel je najjeftiniji u gradu" ➢ Naglasak na marketing - "solidan odnos cijena i vrijednosti" ➢ Standardizirane sobe, meni (samo dvokrevetne sobe, samo tri vrste menija) ➢ Izbjegavanje suvišnih karakteristika proizvoda ➢ Značajna zastupljenost efekta krive iskustva ➢ Mali broj zaposlenih i visoka produktivnost po zaposlenom ➢ Stalna aktivnost na smanjenju troškova ➢ Niska profitna stopa i visoko zauzeće hotelskih, restoranskih kapaciteta
Strategija diferencijacije	➢ Proizvodni aspekti - "naš hotel je jedinstven, sa našom putničkom agencijom imati čete nezaboravni odmor" ➢ Marketing aspekti - "naš hotel je bolji od bilo kog u gradu" ➢ Puno karakteristika (različiti restorani, širok raspon usluga, mogućnost ispunjavanja posebnih zahtjeva, kreiranje paket aranžmana prema specifičnim zahtjevima gostiju) ➢ Stalno inoviranje hotelske ponude i paket aranžmana ➢ Visoke cijene da bi se pokrili dodatni troškovi ➢ Intenzivna promidžbe i prodajna promocija
Strategija fokusiranja	➢ Proizvodni aspekti - "naša usluga je prilagođena vašim zahtjevima i potrebama" ➢ Marketing aspekti - "mi ispunjavamo vaše želje" ➢ Specijalizacija (po različitim kriterijima odabira tržišnih niša-segmenata potencijalnih gostiju) ➢ Konkurentska prednost zavisi od: o Mogućnosti postati troškovni lider na ciljnoj tržišnoj niši (segmentu) o Uspješnog diferenciranja ponude za datu tržišnu nišu (segmentu).

Izvor: prema Porter, *Competitive Advantage (Creating and sustaining superior performance)*, 1985.

Navedena teorijska obilježja generičkih strategija svoju potvrdu dobivaju u praktičnoj primjeni. Hotelska je industrija zbog permanentnog rasta tržišta zahvalna grana kada se sagledavaju rezultati primijenjenih strategija, pri čemu valja uvijek uzimati u obzir da se rast turističkog tržišta temelji na brojnim čimbenicima utjecaja koji su podložni promjenama.

1.12.5 Proces strateškog menadžmenta

Proces strateškog menadžmenta uvažava relevantne činjenice okoline te teži efektivnom i efikasnom ponašanju poslovnog sustava. Primjena procesa strateškog menadžmenta prilikom razvoja konkurentskih sposobnosti hotelskog poduzeća nalazi smisao u činjenici što taj proces poboljšava i unaprjeđuje potencijale tvrtke i rezultira definiranim strategijskim pravcem njegova djelovanja.

Strategije se bez određenih sustava podrške za poslovne operacije ne mogu dobro implementirati ili provesti. Dobro oblikovani vrhunski sustavi podrške ne samo da olakšavaju

provedbu strategije već i jačaju organizacijske sposobnosti te omogućuju konkurentsku prednost nad konkurentima. Izrada i provedba strategije zadaća je cijelog menadžerskog tima. Uspješna provedba strategije zahtijeva vidljivu, jasnu i nepokolebljivu predanost menadžera korištenju najboljih praksi i stalnome napredovanju.

Menadžeri na najvišoj razini moraju se osloniti na aktivnu podršku i suradnju srednjih i nižih menadžera, koji će strateške promjene unositi u funkcijska područja i poslovne jedinice i koji će paziti na to da organizacija uistinu svakodnevno posluje u skladu sa strategijom. Srednji i niži menadžeri ključni su za poticanje svojih podređenih da neprekidno poboljšavaju način izvođenja strateški kritičnih aktivnosti vrijednosnog lanca i za davanje poslovnih rezultata koji omogućuju postizanje ciljeva rada poduzeća.

Strateški menadžment jedan je od preduvjeta uspješnog i efikasnog razvoja poslovnog sustava. Pretvorba strategije u taktičke i operativne iziskuje spremnost i otvorenost za nova saznanja i nepredviđene događaje kako bi se strateški ciljevi realizirali na najbolji mogući način u skladu s promjenama u okolini. Strateški menadžment razvojni je dio strateškog upravljanja poslovnih sustava, a zajedno s implementacijom i kontrolom ukupan sustav čini efikasnijim, vjerodostojnijim, funkcionalnim i ostvarivim, bez obzira u kojem sektoru se primjenjuje.

KRUCIJALNOST PRIMJENE INFORMACIJSKIH TEHNOLOGIJA KAO FAKTOR USPJEŠNOM MENADŽERSKOM ODLUČIVANJU U HOTELSKOM PODUZEĆU

Donošenje poslovnih odluka jedna je od osnovnih zadaća svakoga menadžera u hotelskom poduzeću. Različiti pojedinci svoje odluke temelje na različitim postupcima i pristupima. Hotelska industrija osjetljiva je na brojne čimbenike okruženja i okolnosti, što od menadžera iziskuje stalno praćenje i analiziranje okoline i pravovremenu reakciju na eventualne ugroze poslovanja. Stoga je tematika donošenja odluka predmet brojnih istraživanja u poslovanju, stručnim i znanstvenim raspravama. Poslovna odluka mora biti kvalitetna, što podrazumijeva da je dobra za poduzeće, ispravna i pravodobna. Uloga IT-ja u donošenju odluka može biti dvojaka – savjetodavna ili izvršna, što zavisi o postupku donošenja odluka. U svakom slučaju postojanje odgovarajućega poslovnog informacijskog sustava koji bilježi podatke vezane za poslovanje otvara mogućnost pružanja potpore menadžera u postupcima generiranja, procjenjivanja i konačnoga donošenja odluka.

1.13 Menadžerske odluke i sustavi odlučivanja u hotelskom poduzeću

„Donošenje je odluka proces izbora jednoga od nekoliko alternativnih postupaka radi postizanja jednoga ili više unaprijed postavljenih ciljeva“ (Turban & Aronson, *Decision Support Systems and Intelligent Systems*, 2006). Iz citirane je definicije razvidno kako se pri donošenju odluka menadžer mora opredijeliti između više ciljeva koje je potrebno postići, no oni često mogu biti i međusobno suprotstavljeni ili kontradiktorni. Nadalje, postupci ostvarenja cilja ponekada mogu biti neizvjesni, nepotpuni ili nedovoljno dobro definirani. Sam proces donošenja odluka bitno se razlikuje od pojedinca do pojedinca te od vrste problema, kao i ostalih okolnosti problema.

Postupak donošenja odluka podložan je sljedećim ograničenjima (Bosilj Vukušić & Pejić Bach, 2012):

- spoznajna ograničenja, koja su ograničenja ljudskih sposobnosti za pohranjivanjem i obradom informacija

- ekonomska ograničenja, koja uključuju ograničenu mogućnost uvođenja dovoljnoga broja sudionika u proces donošenja odluka jer tako rastu troškovi donošenja odluke
- vremenska ograničenja, koja se ogledaju u različitim negativnim učincima skraćenoga vremenskog razdoblja u kojemu je potrebno ili čak moguće donijeti odluku.

Sa stajališta primjene informatike, u poslovnom odlučivanju vremensko ograničenje se može izdvojiti kao čimbenik koji može smanjiti rizik od pogrešaka u odlučivanju uslijed izostanka dijela relevantnih informacija. Naime, ma koliko stručan i osposobljen tim stajao na raspolaganju menedžerima za procesuiranje podataka potrebnih za donošenje odluka, ne može se mjeriti s brzinom računalne obrade podataka, što u mnogim slučajevima može biti od krucijalnog značaja.

1.13.1 Vrste odluka i modeli odlučivanja

Općenito, modeli služe kako bi se moglo 1) unaprijed sagledati većinu relevantnih elemenata problema i kako bi se otkrile njihove bitne međuovisnosti, 2) eksperimentirati na modelu, što je mnogo jeftinije i brže od eksperimenata u stvarnosti te 3) u dinamičnom svijetu u kojem se ograničenja i okolnosti stalno mijenjaju efikasno i brzo reagirati njihovim ugrađivanjem u model (Baračkai, 1987, str. 30).

U tom kontekstu modeli odlučivanja mogu biti korišteni da prikažu proizvodni ili uslužni sustav matematičkim izrazima. Svrha modela odlučivanja je „pronalaženje optimalnih ili zadovoljavajućih vrijednosti varijabli odlučivanja koje poboljšavaju performanse sustava unutar primjenjivih ograničenja“ (Schroeder, 1989, str. 7). Takvi modeli onda mogu pomoći u usmjeravanju menadžmenta kod donošenja odluka.

Modeli odlučivanja omogućuju da se između različitih alternativnih rješenja, testiranjem i simulacijom iznađe „najbolje rješenje“, sukladno s postavljenim ciljem rješavanja nekog konkretnog poslovnog problema.

Da bi menadžeri ostvarili zadane poslovne ciljeve, oni moraju razumjeti proces odlučivanja, kako se odluke donose i kako se modeli i tehnike (metode, alati) za donošenje odluka kod toga koriste. O kvaliteti donesenih poslovnih odluka zavisit će uspjeh ili neuspjeh poslovanja. Poslovna odluka ne bi smjela biti ishitrena i hazarderska već treba biti donesena analitičkim procesom odlučivanja, temeljeći se na logici i uzimajući u obzir sve raspoložive podatke i

moguće inačice. Ovakva odluka, prema Heizeru i Renderu (1996, str. 53-55), slijedi ovih šest faza:

1. Definirati problem i čimbenike koji na njega utječu! Problem o kome treba odlučivati mora biti prikazan jasno i koncizno, što je u mnogim slučajevima najvažnija, ali i najteža faza.
2. Utvrditi kriterije odlučivanja i ciljeve! Menadžeri moraju razviti specifične mjerljive ciljeve.
3. Formulirati model ili međusobni odnos (povezanost) između ciljeva i varijabli! Najveći broj modela sadrži jednu ili više varijabli.
4. Prepoznati i (pr)ocijeniti inačice! Menadžeri trebaju generirati toliko mnogo solucija (rješenja) koliko je to moguće, ali i obično brzo izvedivo. Većina menadžera voli imati niz ili set opcija (mogućih rješenja) kako bi mogli (pr)ocijeniti svaku opciju s obzirom na njezine jake strane (prednosti) i slabe strane (nedostatke).
5. Odabrati najbolju inačicu! To je inačica kojom se najbolje zadovoljavaju ciljevi, a s njima je i najkonzistentnija.
6. Primijeniti (provesti) odluku! Stavljanje u postupak izvođenja odabrane inačice može biti najteža faza odlučivanja. Provedba odluke uključuje dodjelu (raspored) zadataka i vremenske rokove za njihovo izvršenje.

Iz ovog je vidljiva nezamjenljiva uloga koju modeli imaju u procesu odlučivanja. Modeli se koriste da bi se pomoću njih što vjernije prikazao neki realni sustav i to izradom kopije koja dobro odražava njegova svojstva, izgled i značajke.

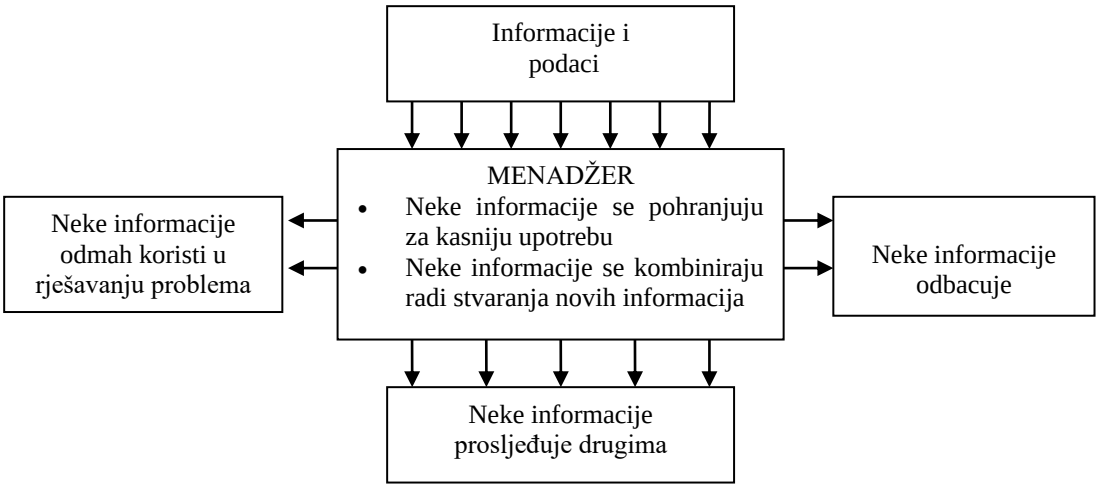
1.13.2 Poslovno i menadžersko odlučivanje

Poslovno odlučivanje u doba brzih i diskontinuiranih promjena, što je obilježje novog milenija, nije moguće bez učinkovite informacijske podrške. U tom kontekstu valja promatrati i djelovanje hotelskog menadžmenta, kojem je raspoloživost informacija preduvjet za donošenje kvalitetnih poslovnih odluka. Još 1988. godine Thierauf (*User-Oriented Decision Support Systems,* str. 3) je smatrao kako je „informacija postala ravnopravni šesti organizacijski resurs uz onih pet tradicionalnih: ljude, strojeve, novac, materijale i menadžment“. Srića (*Informatika i menadžment,* 1933, str. 54) je naglašavao kako je „značenje informacije kao organizacijskog resursa mnogo veće nego što je to bilo prije trideset godina i da svakim danom sve više raste“.

Informacija je, kako navode Davis i Olsen (*Management Information Systems: Conceptual Foundations, Structure and Development,* 1985, str. 200) resurs „ koji se ne troši uporabom niti smanjuje raspodjelom“. Njome se otklanja određena veća ili manja količina neizvjesnosti; na taj se način njezin korisnik dovodi u povoljniju situaciju nego što je bio prije primitka informacije.

Upotrebljiva ***poslovna informacija*** mora osigurati validnu i pouzdanu sliku stvarnosti, biti raspoloživa u pravo vrijeme, biti kompletna i konzistentna i, što je najvažnije, biti relevantna za domenu poslovnog odlučivanja. Pri donošenju odluka informacije imaju veliku vrijednost upravo zato što se velik broj odluka donosi pri određenom stupnju rizika ili pri neizvjesnosti. To osobito vrijedi za poslovne odluke. Svaka dodatna korisna informacija može olakšati proces odlučivanja i pomoći odgovarajućem razrješenju problemske situacije u poduzeću. Griffin je još 1990. godine ustvrdio kako „informacijski sustavi predstavljaju 'krvotok' suvremene organizacije, jer pružaju 'hranu' donositeljima odluka u rješavanju problemskih situacija“ (*Management*, treće izdanje, str. 663). Do današnjih dana ova sintagma vrijedi uz napomenu da se količina informacija umnogostručila, kao i brzina kojom se te informacije procesuiraju. Pojednostavljeni tijek informacija relevantnih za donošenje poslovnih odluka predočava se narednom slikom.

Slika 12. Procesuiranje informacija



Osnovna je svrha kreiranja poslovnog informacijskog sustava rješavanje poslovnih problema. Poslovni problemi proizlaze iz različitih promjena s kojima se u svojem poslovanju hotelsko poduzeće susreće. To mogu biti promjene: 1) u okolini hotela, 2) u ciljevima i željama

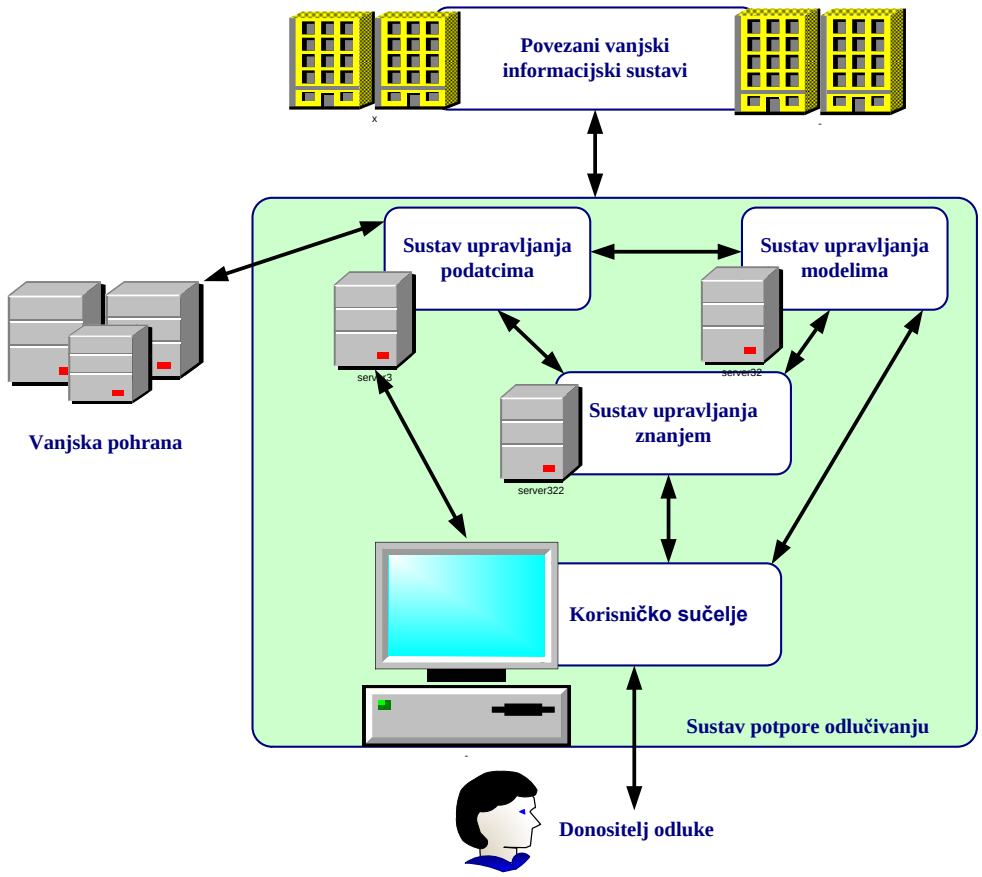
upravljačkog sloja, 3) u funkcioniranju poslovanja hotela i pojedinih podsustava, 4) odnosa u vezi s organizacijskim ulogama i 5) međuljudskih odnosa.

Ovisno o generaciji implementiranog informacijskog poslovnog sustava, od njega se očekuje da pruži podršku, predlaže optimalna rješenja te da samostalno donosi poslovne odluke u pojedinim ponavljajućim procesima gdje se model odlučivanja ne mijenja, nego samo njegove ulazne varijable.

1.13.3 Sustavi za podršku u menadžerskom odlučivanju

Sustavi potpore odlučivanju su računalni informacijski sustavi koji podupiru rješavanje nestrukturiranih menadžerskih problema s ciljem poboljšanja kvalitete donesenih odluka. Neke od presudnih značajki sustava potpore odlučivanju su njihova interaktivnost, fleksibilnost i prilagodljivost (problemskoj situaciji, ali i donositeljima odluka). Građa tipičnoga sustava potpore odlučivanju prikazana je narednom slikom.

Slika 13. Struktura generičkoga sustava za potporu odlučivanju



Izvor: Varga i Strugar, *Informacijski sustavi u poslovanju*, 2016, str. 115.

Sustavi za podršku menadžerskom odlučivanju (engl. *Decision Support Systems* – DSS) započinju svoj razvoj ranih 70-ih godina 20. stoljeća pod nazivom *Management Decision Systems*. U to vrijeme takve sustave obilježavali su računalni interaktivni sustavi sposobni za rješavanje nestrukturiranih problema. Daljnji je razvoj išao preko korištenja odgovarajuće i dostupne tehnologije za poboljšanje aktivnosti menadžmenta uporabom softvera, pri čemu je koncept proširen uključivanjem metoda operacijskih istraživanja, sustavne analize i psihologije. Sredinom 80-ih godina razvijena je nova tehnološka osnova – inteligentne radne stanice, što je uz razvoj telekomunikacijske tehnologije omogućilo promjenu u organizacijskom pristupu DSS-u. Naime, otvoreno je pitanje centralizacije i decentralizacije u konceptu informacijskog sustava poduzeća, odnosno opravdanost izgradnje distribuiranog DSS-a. Istovremeno se javljaju i nove tehnologije, kao što su ekspertni sustavi i sustavi zasnovani na dokumentaciji. Sve je to potaklo na redefiniciju DSS-a, koji bi trebao predstavljati „eksploataciju intelektualnih i računalno povezanih tehnologija za poboljšanje kreativnosti u odlučivanju“ (Sol, 1987, str. 6). Prema tome, put do DSS-a (u fokusu kojega je odlučivanje) vodi od EOP-a (u fokusu kojega je podatak) preko MIS-a (u fokusu kojega je informacija), tako da između ovog posljednjeg i DSS-a postoje sličnosti i razlike (Klepić, 2019), a što je predočeno narednim prikazom.

Slika 14. Usporedba između MIS-a i DSS-a

MIS	DSS
Fokus za strukturirane zadatke i rutinske odluke (npr. uporaba procedura, uporaba pravila odlučivanja)	Fokus za polu-strukturirane zadatke koji zahtijevaju menadžersku prosudbu
Naglasak na pohrani podataka	Naglasak na rukovanju podacima
Često samo indirektno pristup menadžera	Direktni pristup menadžera podacima
Oslonac na računalne eksperte	Oslonac na vlastitu prosudbu menadžera
Pristup podacima eventualno zahtijeva promjene kod menadžera prilikom posluživanja	Direktan pristup računalu i podacima
Menadžer nepotpuno razumije prirodu odluke	Menadžer poznaje okolinu odluke
Naglasak na efektivnosti	Naglasak na efikasnosti

Izvor: Klepić, Z. *Donošenje odluka, Sistemi za potporu odlučivanju*, nastavni materijali, http://ef.sum.ba/sites/default/files/nastavni-materijali/dono%C5%A1enje%20odluka.pdf [pregledano 25.11.2019]

Glavno je obilježje DSS-a da je on projektiran kao pomoć menadžerima prilikom odlučivanja o nestrukturiranim problemima, tj. onim problemima koji nisu svakodnevni, rutinski i dobro

poznati. On doduše ne djeluje automatski i ne zamjenjuje menadžere u procesu donošenja odluka, već im daje potporu pri donošenje odluka.

1.13.4 Metode potpore odlučivanju

Donošenje odluka jedna je od osnovnih zadaća svakoga menadžera. Različiti pojedinci svoje odluke temelje na različitim postupcima i pristupima. Hoće li se i u kojoj mjeri pri formiranju i donošenju poslovne odluke koristiti računalnim informacijskim sustavima koji poboljšavaju njihovu kvalitetu ovisi o situaciji, složenosti problema, okruženju, ali i resursima kojima raspolaže. Bitne su značajke sustava potpore odlučivanju njihova interaktivnost, fleksibilnost i prilagodljivost (problemskoj situaciji, ali i donositeljima odluka).

Razumljivo je, da programi PI-a ma koliko sofisticirani bili, ne mogu riješiti problem koji nije modeliran te je isto tako razumljivo da menadžer-korisnik mora posjedovati odgovarajuća znanja o modelima kojima se želi služiti. Varga i Strugar (2016) izdvojili su sljedeće grupe metoda:

1) ***Optimizacijske metode*** koriste se za pronalaženje rješenja problema matematičkim modelima koji će postizati najbolje moguće rezultate uz zadana ograničenja. Dva su moguća cilja optimizacije: (1) maksimizacija vrijednosti rješenja i (2) minimizacija vrijednosti rješenja. U hotelskom poslovanju najčešće su to modeli maksimizacije profita ili modeli minimizacije troškova poslovanja. Za postizanje takvih rješenja koriste se: 1) model linearnog programiranja i/ili 2) model analitičkog hijerarhijskog procesa – AHP. Od menadžera se ne očekuje poznavanje modeliranja, već poznavanje pristupa kojim dolazi do rješenja.
2) ***Simulacija i modeliranje procesa*** koristi se za prikaz onih sustava koje nije moguće opisati i modelirati matematičkim sredstvima, a to su dinamički sustavi, tj. sustavi koji se mijenjaju u vremenu (redovi čekanja, proizvodni procesi, promet, ekonomski problemi, rast populacije, problemi ekologije). Pomoću simulacijskoga modeliranja rješavaju se različiti problemi vezani uz donošenje odluka: razumijevanje problema (mjerenje utjecaja određenih parametara na rad cijeloga sustava), analiza rada sustava (performanse, kapaciteti resursa, uska grla poslovnih procesa) i oblikovanje sustava (usporedba alternativnih scenarija i izbor najboljega rješenja), a često se koristi i za trening donositelja odluka (poslovne igre, ratne igre);
3) ***Sustavska dinamika*** je metoda kontinuirane simulacije koja istražuje značajke složenih dinamičkih sustava s povratnom vezom. Korištenjem kvalitativnih i kvantitativnih modela

sustavske dinamike mogu se analizirati posljedice donošenja odluka. Metodom sustavske dinamike može se istražiti na koji bi način odluka o promjeni cijena smještaja utjecala na potražnju. Metoda sustavske dinamike analizira sustave s povratnom vezom, što znači da analizira posljedice koja djeluje na uzrok. Primjerice, ako zaposlenici u hotelu rade pod stresom, radit će pogreške u radu te će se njihov stres još povećati. Povratne veze mogu biti: 1) pozitivne, koje djeluju tako da povećanje vrijednosti promatranoga elementa sustava uzrokuje promjene koje će još više povećati taj isti element i 2) negativne, gdje smanjenje vrijednosti elementa sustava uzrokuje promjene koje će još više smanjiti vrijednost tog elementa.

4) ***Metode umjetne inteligencije.*** Umjetna je inteligencija znanstveno polje unutar računalnih znanosti koje se bavi proučavanjem i dizajnom inteligentnih agenata (Varga & Strugar, 2016, str. 128). Pod inteligentnim agentom podrazumijeva se sustav koji percipira svoju okolinu temeljem čega planira svoje djelovanje u toj okolini radi postizanja zadanih ciljeva. Ciljevi su umjetne inteligencije izrada metoda za zaključivanje, rješavanje složenih problema, prikaz znanja, planiranje, strojno učenje, obrada prirodnog jezika, percepcija i pokretanje. Dugoročni ciljevi podrazumijevaju proučavanje društvene inteligencije, kreativnosti i opće inteligencije. Od metoda umjetne inteligencije koje se koriste kao potpora odlučivanju, najznačajniji su: 1) ekspertni sustavi koji koriste znanje za rješavanje problema čije rješavanje zahtijeva visoku razinu stručnosti ljudskih eksperata i 2) inteligentni softverski agenti koji pronalaze svoju primjenu u različitim segmentima poslovanja u kojima postoji velika količina informacija koje treba obraditi ili sažeti te ih učiniti dostupnima prosječnom korisniku ili donositelju odluka.
5) ***Meko računarstvo*** čine metode koje se koriste kod vrlo složenih problema kod kojih čimbenici koji djeluju na problem nisu dovoljno poznati i nalaze se u području pretpostavki i vjerojatnosti. Pojavljuju se u stvarnome poslovnom okruženju, a nije ih moguće čak niti precizno i potpuno opisati, niti je moguće u potpunosti vjerovati istinitosti informacija i znanja kojima se oni predstavljaju. Zbog nedorečenosti informacija, pokušava se pronaći približna rješenja koja mogu poduprijeti donošenje konačne odluke. Glavni model funkcioniranja mekog računarstva temelji se na modelu ljudskoga uma. U skupinu metoda mekog računarstva spadaju: 1) neizrazita logika, 2) neuronske mreže, 3) genetički algoritmi i 4) teorija kaosa.

Sve su navedene metode dizajnirane na način da ih kao potporu odlučivanju koristi menadžer – donositelj odluke, koristeći se nekom od računalnih aplikacija u kojoj su

inkorporirane sve ili neke od navedenih metoda. Međutim kod složenijih problema s kojima se u poslovanju susreću hotelska poduzeća, a koji mogu izazvati značajne financijske implikacije ili poremećaje u poslovanju, tada se odluke ne prepuštaju pojedinom menadžeru, već se određuje skupina donositelja odluka (u obliku odbora, povjerenstava ili jednostavno radnih skupina i projektnih timova), koji zajedničkim naporima donose odluke.

U takvoj situaciji odabir najboljega rješenja poslovnoga problema dodatno se usložnjava potrebom konsenzusa svih uključenih u proces donošenja odluke pa stoga takvo donošenje odluka zahtijeva specifične oblike potpore, tzv. potporu odlučivanju u skupini.

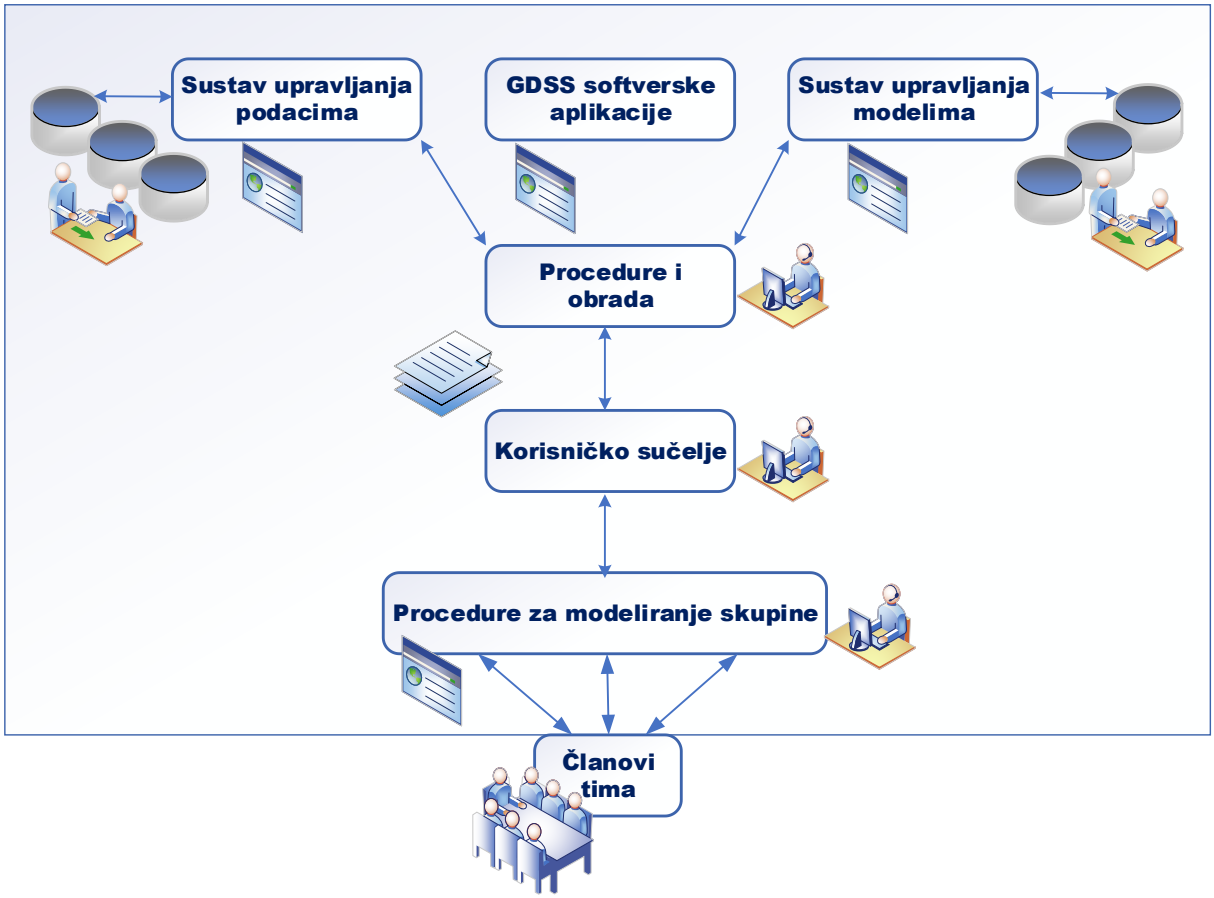
1.13.5 Sustav potpore odlučivanja u skupini – GDSS

Sustav potpore odlučivanja u skupini (engl. *Group Decission Support System – GDSS*) interaktivni je računalni sustav koji podupire skupinu donositelja odluka tijekom procesa rješavanja nestrukturiranih oblika problema. To je zaseban sustav koji je osmišljen radi rješavanja nekoga specifičnog problema ili klase problema, a podržava različite uloge i zaduženja pojedinih članova skupine.

Sustav za potporu odlučivanju u skupini sadrži softverske aplikacije koje su prilagođene grupnom donošenju odluka, koje se mogu sastojati od softverskih aplikacija za komunikaciju i suradnju. Neke od GDSS softverskih aplikacija uključuju *Expert Choice Comparion, Grouputer* i *Logical Decission far Groups*. Razina funkcionalnosti ovisi od aplikacije do aplikacije a često uz alate za potporu donošenju odluka u skupini obuhvaćaju i općenite alate za suradnju, tj. moderiranje timskoga rada. Pritom je poseban naglasak na postupke generiranja i organiziranja ideja članova tima, zatim određivanja prioriteta ideja i konačnoga vrednovanja.

Generička struktura sustava za potporu odlučivanja u skupini predočava se narednom slikom.

Slika 15. Generička struktura sustava za potporu odlučivanja u skupini



Izvor: prema Varga i Strugar, *Informacijski sustavi u poslovanju*, 2016, str. 139.

Od metoda uobičajena je primjena analitičkog hijerarhijskog procesa (AHP), ali i drugih metoda za višekriterijsko donošenje odluka (engl. *Multi-Objective Decission Analysis* – MODA).

1.13.6 Sustavi podrške odlučivanju (DSS)

Sustav za podršku odlučivanju (DSS) je „interaktivni računalni sustav lako dostupan stručnjacima i donositeljima odluka (koji nisu specijalisti za računalnu tehnologiju), a koji im pomaže u funkcijama planiranja i poslovnog odlučivanja“ (Turban & Meredhith, 1991, str. 883). Svrha sustava za podršku odlučivanju nije donošenje odluke umjesto menadžera, već pružanje određenog seta informacijskih „pomagala“ koji će im omogućiti prikupljanje i

stvaranje informacija za koje oni smatraju da su im potrebne kod odlučivanja. Sustavi za podršku odlučivanju projektiraju se u namjeri da se menadžerima pomogne u svladavanju problemskih područja u odlučivanju koje nije svakodnevno, rutinsko i dobro poznato, nego je samo jedan njegov dio poznat, djelomično strukturiran ili nije uopće strukturiran.

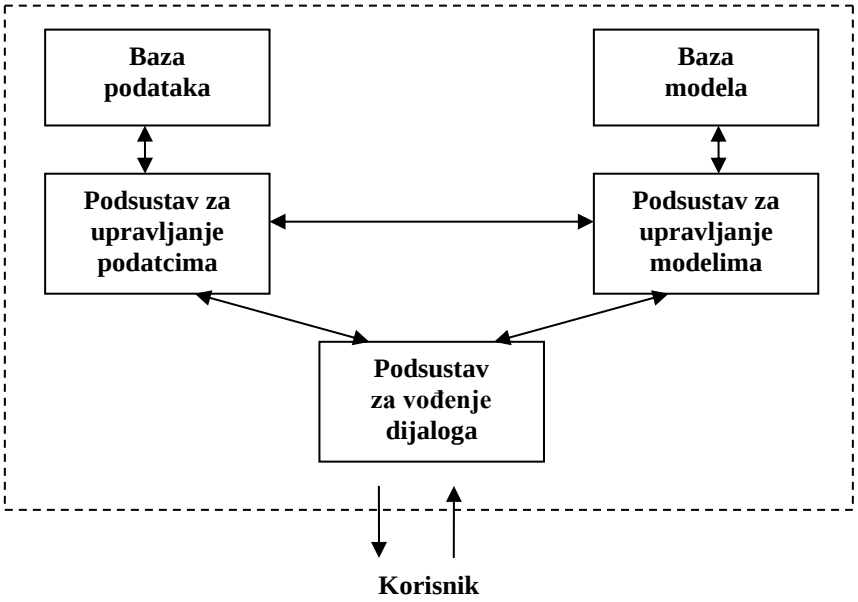
Sustavi za podršku odlučivanju daju potporu donositeljima odluka, ali proces odlučivanja ne čine automatskim; ne zamjenjuju menadžere uviđanju, prosudbama i heurističkim funkcijama odlučivanja. Korištenjem sustava za podršku odlučivanju, menadžeri mogu kreirati baze podataka i modela na način koji ne mora biti unaprijed propisan niti predviđen.

Postoji više sustava za podršku odlučivanju ali Sprague i Carlson *(Building Effective Decision Support Systems,* 1982, str. 250-277) izdvajaju tri osnovna oblika:

1. Specifični DSS je kompletna aplikacija koja sadrži mnogo opcija koje korisnicima dopuštaju pronalaženje ili generiranje informacije potrebne za pojedina problemska područja, primjerice financijsku ili tržišnu analizu.
2. DSS generatori, nasuprot specifičnim sustavima za podršku odlučivanju koji su kompletne aplikacije, dizajnirani su za uporabu u brzom kreiranju i generiranju različitih aplikacija.
3. DSS alate čine elementi hardvera, softvera, procedura i podataka koji omogućavaju izgradnju bilo specifičnih DSS-ova, bilo DSS generatora. DSS alati su specijalni slučajevi DSS generatora. Oni su također namijenjeni razvoju sustava za podršku odlučivanju, ali imaju ograničen i poseban fokus.

Komponente sustava za podršku odlučivanja čine podsustavi za upravljanje modelima, podatcima te za vođenje dijaloga. Temeljnica je podsustava baza u kojoj se čuvaju osnovni modeli sustava. Baza modela sadrži skup različitih vrsta modela s osnovnim ciljevima koji su slični onima koje ima i baza podataka. Kad korisnik želi dobiti određenu vrstu podataka, on na temelju pristupa bazi modela može odabrati vrstu modela koju će koristiti. Sprague i Carlson (*Building Effective Decision Support Systems,* 1982, str. 269-270.) navode da se modeli predstavljaju i pohranjuju ili u obliku potprograma ili u obliku vezanoga skupa podataka. Narednom slikom predočava se sustav za potporu odlučivanju.

Slika 16. Podsustavi sustava za podršku odlučivanja



Izvor: obrada autora

Sama baza modela sastoji se, kako Turban i Meredhith (*Fundamentals of Management Science*, 1991, str. 839) ističu, od gotovih računalnih programa i modelskih blokova koji korisniku omogućavaju da sam gradi *ad hoc* aplikacije. U kvalitetnim sustavima za podršku odlučivanja vrlo je bitna veza među različitim modelima koji se sekvencijski koriste, kao i brz i učinkovit pristup modelima.

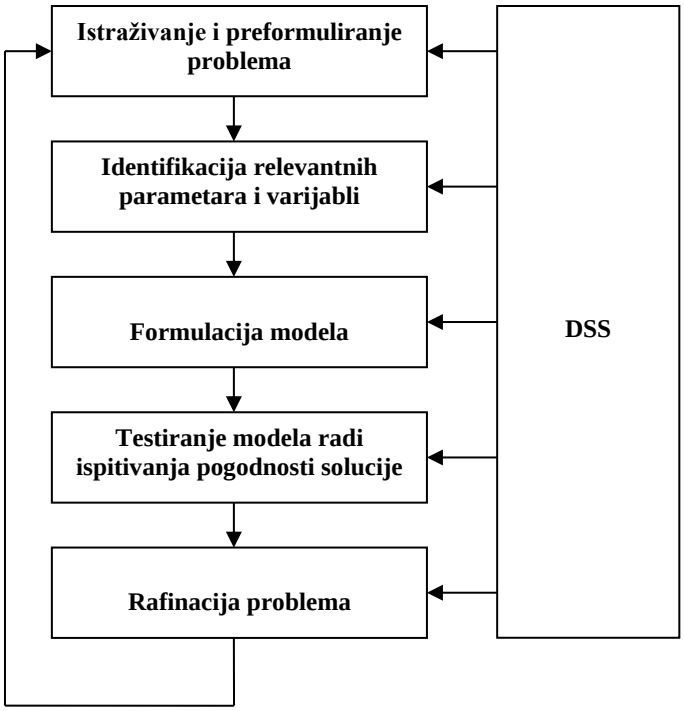
Primjena sustava za podršku odlučivanju usko je vezana za proces rješavanja problema na srednjim i višim razinama menadžmenta. Takvi problemi, kao i sam proces odlučivanja, imaju obilježja znatne nestrukturiranosti pa je primjena sustava za podršku odlučivanju u pravilu iterativan proces. Proces uporabe sustava za podršku odlučivanju može se vizualizirati u pet faza. Ponajprije, donositelji odluka moraju istražiti i formulirati problem, nakon čega treba prepoznati relevantne parametre i varijable koji mogu pomoći razumijevanju situacije od strane korisnika.

Model se gradi povezivanjem parametara i varijabli na način kako to opiše korisnik. Premda korisnik može razumjeti kako su činitelji vezani jedan s drugim, u mnogim slučajevima za neke

dijelove originalnog problema može nedostajati takvo znanje. Stoga je model katkad samo ideja koja treba proći proces testiranja.

Narednom slikom predočava se proces rješavanja problema – sustav za podršku odlučivanja.

Slika 17. Proces rješavanja problema – sustav za podršku odlučivanja



Izvor: obrada autora

Testiranje modela uključuje „opskrbu“ varijabli s podatcima i njihovo procesiranje radi dobivanja rezultata. Ovisno o aplikaciji, test varijable mogu biti profiti i gubici, razine prodaje, kamatne stope, razine kvalitete i slično. Model predviđen za nestruktirirani problem rijetko je kad ispravan pri prvom dizajniranju. Zato je u procesu izradbe sustava za podršku odlučivanja potrebno izvršiti rafinaciju problema, kao i identifikaciju dodatnih ili različitih podataka koji će ući u razmatranje.

1.13.7 Sustavi podrške grupnom odlučivanju (GDSS)

Sustav za podršku skupnom odlučivanju (engl. *Group Decision Support Systems* – GDSS) nastaju proširivanjem koncepta sustava za podršku odlučivanja posebnim komunikacijskim sredstvima tipa „čovjek-računalo-čovjek“ tako da se omogući podrška donošenja odluka od strane skupine menadžera. Za razliku od sustava za podršku koji su koncipirani za individualnu

primjenu, sustavi za podršku grupnom odlučivanju projektiraju se kako bi podržali zajednički proces odlučivanja skupine ljudi. To znači da su „GDSS interaktivni, računalno bazirani sustavi koji olakšavaju rješavanje nestrukturiranih problema skupini donositelja poslovnih odluka“ (Turban & Meredhith, 1991, str. 845).

Grupno odlučivanje vezano je prvenstveno uz velike korporacije koje posluju na područjima više država s različitim političkim, pravnim i poreznim sustavima, što donošenje jednostranih odluka čini rizičnim. U hotelskoj industriji djeluju mnogi internacionalni lanci koji se u svojem poslovanju upravo susreću s takvim problemima. Suvremena tehnologija omogućava audiovizualni kontakt putem videokonferencija, odnosno poslovnih sastanaka, što uključuje i mogućnost korištenja sustava za grupno odlučivanje. GDSS se zasigurno neće koristiti u svakodnevnom poslovanju, već je njegova primjena namijenjena kod donošenja odluka od većeg značaja, poput investiranja u nove hotele u nekim novim državama ili pak za smanjivanje i prodaju nekih objekata. Prednosti koje pruža GDSS odražavaju se naročito kod naglih promjenama u okruženju (politička kriza, valutna kriza, ratna ili teroristička djelovanja), odnosno u situacijama kada se brzo moraju donositi krucijalne odluke. Prednosti GDSS-a u takvim situacijama ogledaju se jer on (Senn, 1990, str. 556):

- funkcionira kao memorija cijele skupine – izbjegava se ponovno procjenjivanje ideja od članova skupine
- pomaže identifikaciji primjenjivih alternativa
- alternative se stvaraju nakon pažljivijeg razmatranja
- podiže sposobnost skupine u međusobnom komuniciranju i širenju ideja
- služi kao sredstvo za interakciju između zainteresiranih strana za donošenje odluka u poduzeću.

Konfiguracija sustava za podršku grupnom odlučivanju varira ovisno o vrsti poslovnih aplikacija. Za razliku od drugih klasa informacijskih sustava, sustav za podršku skupnom odlučivanju posebno je dizajniran sustav, a ne konfiguracija već postojećih komponenti.

1.14 Menadžerski informacijski sustavi – MIS

Menadžerski informacijski sustav – MIS predstavlja takav sustav u kojemu međusobno povezani elementi hardvera i softvera produciraju odgovarajuće rezultate (izvještaje i drugo) za potrebe menadžmenta.

Osnovna je svrha MIS-a da podržava menadžerske aktivnosti u poduzeću pa se stoga i s aspekta tih aktivnosti može vršiti njegovo strukturiranje. Obično se razlikuju tri grupe menadžmentskih aktivnosti, koje su hijerarhijski poredane, a to su:

- strateško planiranje, nositelj kojega je vrhovni menadžment, a koji ima zadatak definirati strategije za ostvarenje ciljeva poduzeća
- menadžment kontrola, nositelj koje je srednja razina menadžmenta, a koja ima zadatak osigurati i alocirati potrebne resurse te postaviti i nadzirati budžetska ostvarenja
- operativna kontrola, nositelj kojega je prva razina menadžmenta, a koja ima zadatak da efikasno upotrijebi postojeće resurse za izvođenje aktivnosti unutar budžetskih ograničenja.

Zadatak MIS-a je da svaku od navedenih grupa menadžerskih aktivnosti opskrbljuje odgovarajućim informacijama, pri čemu treba imati u vidu da se te informacije po svojim karakteristikama razlikuju od jedne do druge grupe ovih aktivnosti. To je uočljivo predočeno narednom slikom.

Slika 18. Zadatci MIS-a

KARAKTERISTIKE INFORMACIJA	OPERATIVNA KONTROLA	MENADŽERSKA KONTROLA	STRATEŠKO PLANIRANJE
Izvor	**Interni**	⟷	**Eksterni**
Domašaj	**Malen**	⟷	**Širok**
Agregiranost	**Mala**	⟷	**Velika**
Vremenski horizont	**Prošlost**	⟷	**Budućnost**
Frekventnost	**Visoka**	⟷	**Niska**
Točnost	**Visoka**	⟷	**Niska**
Repetitivnost	**Visoka**	⟷	**Niska**
Obujam	**Veliki**	⟷	**Mali**
Tip informacije	**Kvantitativna**	⟷	**Kvalitativna**

Izvor: obrada autora

Navedene razlike u karakteristikama informacija uvjetuju i postojanje različitih baza podataka i načina njihova ažuriranja.

Dok baza podataka za operativnu kontrolu sadrži interne podatke koji su generirani iz procesa obrade podataka (DP, odnosno TPS), dotle baza podataka strateškog planiranja sadrži podatke uglavnom dobivene iz okoline. Što se pak tiče menadžerske kontrole, njegzina se baza podataka sastoji od dva dijela: 1) baze podataka osigurane pomoću operacija (iz DP odnosno TPS) i 2) baze zadanih parametara (planovi, budžeti standardi i sl.).

Strukturu MIS-a moguće je definirati i s aspekta organizacijskih funkcija koje produciraju i koriste određene informacije. Problem je što ne postoji standardna klasifikacija ovih funkcija pa se stoga i ne mogu izvoditi generalizirani opće važeći informacijski sustavi. Međutim u

teorijskim se analizama ipak najčešće polazi od četiri tipične funkcije: proizvodnje, marketinga, financija i kadrova.

Svaka od ovih funkcija ima jedinstvene potrebe i svaka za to traži dizajniranje posebnog sustava informacijske podrške. U tom se smislu u poduzećima najčešće razvijaju četiri funkcionalna podsustava MIS-a, bez obzira je li poduzeće organizirano na funkcijskoj ili divizijskoj osnovi.

Navedeni funkcijski podsustavi obavljaju kako operativne tako i taktičke te strateške aktivnosti pa se stoga i u njihovom okviru odvijaju ranije navedene menadžmentske aktivnosti. Na toj se osnovi formira matrica funkcijskih podsustava i menadžment aktivnosti, osnovicu koje čini proces transakcija.

1.14.1 Razine menadžerskog informacijskog sustava

U ranijem je izlaganju bilo riječi o elementima obradne strukture menadžerskog informacijskog sustava, bazama podataka, mrežama i ljudskim resursima kojima je na izvjestan način iscrpljena problematika djelatne strukture MIS-a. Time je ujedno dan i odgovor na pitanje kako i na koji način se vrši obrada podataka i njihovo transformiranje u informacije potrebne za donošenje odluka. Ostaje stoga zadatak da se sada ukaže na dva ključna aspekta – menadžerske aktivnosti i poslovne funkcije – bez uključivanja kojih se i ne bi moglo govoriti o MIS-u, već samo o obradi podataka.

Kada se govori o menadžerskom aspektu informacijskog sustava, onda se uvijek imaju u vidu tri osnovne razine menadžmenta – a) najnižu, b) srednju i c) najvišu razinu menadžmenta – na kojima se odvijaju odgovarajuće grupe aktivnosti za izvršenje kojih je potrebno osigurati kvalitetne informacije.

Najniža, prva razina menadžmenta, razina je operacija koje se odvijaju radi izvršenja postavljenih operativnih zadataka pa se stoga govori i o operativnoj razini. Kako je kontrola uporabe raspoloživih resursa unutar zadanih ograničenja glavni zadatak ove razine menadžmenta, onda se govori o ovoj razini menadžmenta kao o razini operativne kontrole, odnosno operativnom menadžmentu. Ova je razina menadžmenta zainteresirana za implementaciju i kontrolu aktivnosti hotelskog poduzeća, u čemu je veoma ovisna o formalnim procedurama. Informacije koje služe u tu svrhu isključivo su interne naravi – one izviru iz samih operacija – a odluke koje se donose pretežno su programirane s obzirom na to da su problemi

veoma strukturirani. Obujam podataka i informacija koje izviru iz operacija veoma je velik, a pritjecanje informacija je kontinuirano u tijeku rada.

Stoga je obrada tih podataka i informacija veoma mukotrpan posao ako se vrši manualno – tek primjena računala ovu obradu čini efikasnom. Važnost efikasne obrade podataka na operativnoj razini od bitnog je značenja s obzirom na to da je nadzor nad odvijanjem operacija intenzivan, a potreba donošenja odluka velika, a često i u realnom vremenu. Stoga su mnogi operativni informacijski sustavi zasnovani na elektroničkoj obradi podataka. Baza podataka obuhvaća podatke iz operativnih transakcija, o čemu operativni menadžment dostavlja podatke pomoću različitih izvještaja (o proizvodnji, kvaru, izostancima s posla, troškovima itd.). Glavno je pitanje ove razine obrade koji način obrade podataka aplicirati – serijsku obradu *(Batch Processing)* ili obradu neposrednim pristupom *(Real Time Processing)*? Odgovor na ovo pitanje nalazi se u frekvenciji odluka koje treba donositi na operativnoj razini – u slučaju kada se traži promptni odgovor, neposredni pristup bit će neophodan; u svim ostalim slučajevima serijska obrada će biti zadovoljavajuća. S obzirom na to da na operacijskoj razini postoji potreba i za promptnim odlukama, kombinacija oba načina obrade podataka je najčešća.

Srednja razina menadžmenta ima zadatak osigurati i alocirati potrebne resurse te postaviti i nadzirati budžetska ograničenja, što je veoma složen zadatak, za čije su izvršenje potrebne interne i eksterne informacije formalne i neformalne naravi. S obzirom na to da su menadžeri okrenuti okolini, kompleksnost i neizvjesnost koja u toj okolini vlada presudno utječe na bonitet njihovih odluka. Upravo se stoga MIS i gradi, da bi osigurao podršku odlučivanju srednjem menadžmentu u ostvarivanju menadžerske kontrole. Međutim problem je u tome što je ova razina menadžmenta komponirana od veoma različitih funkcionalnih cjelina (poslovne funkcije) koje „zasijecaju“ različite segmente okoline pa je stoga nužno oblikovati i različite podsustave unutar MIS-a.

Modeli optimizacije, čija primjena dolazi do posebnog izražaja na operativnoj razini, ovdje nisu presudni s obzirom na to da se na ovoj razini zahtijeva menadžerska sposobnost rasuđivanja, inicijativa i poduzetnost. Međutim to ne znači da modeli optimalizacije ne mogu biti od pomoći pri donošenju taktičkih odluka.

Taktička razina menadžmenta provodi strateške odluke i nadzire odvijanje operacija u koju svrhu informacijska povratna sprega ima presudnu ulogu. U tu se svrhu koriste različite metode i tehnike kontrole (budžetska kontrola, kontrola kvalitete, kontrola zaliha, itd.), kao i tri tipa povratne veze, i to (Lucey, 1995, str. 210):

- konvencionalna povratna sprega, koja se koristi za rutinsko izvještavanje inicirajući korektivne akcije u slučaju devijacija
- adaptivna povratna sprega, koja se koristi za korekciju kratkoročnih planova i budžeta u slučaju promjene uvjeta pod kojima su planovi i budžet donijeti
- „krizna“ povratna sprega, koja se koristi za korekcije supstancijalnih ili nekontroliranih devijacija planova, a koje mogu imati implikacijama strateške planove.

Da bi se osiguralo funkcioniranje navedenih tipova povratne veze, menadžment mora biti opskrbljen dovoljnom količinom i kvalitetom informacija. One mu pristižu iz različitih izvora, a njegova je uloga da ih prosuđuje, u čemu mu značajnu podršku može dati računalno zasnovan MIS. U tu se svrhu razlikuju četiri tipa formalnog MIS-a, a to su (Lucey, 1995, str. 210-211):

- sustavi kontrole, koji nadziru i izvještavaju o aktivnostima hotelskog poduzeća, koristeći pretežno interne izvore informacija, ali ne zanemarujući ni one ključne eksterne (konkurentske akcije, cijene inputa, kretanje plaća, itd.)
- sustavi baza podataka, koje prikupljaju, obrađuju i memoriraju interne i eksterne informacije kako bi za potrebe poduzeća osigurale bazu podataka
- sustavi pretraživanja, koji omogućavaju planirano i *ad hoc* pretraživanje baze podataka, bilo one za interne potrebe, bilo one za eksterne potrebe, pružajući osnovu za različite prognoze
- sustavi za podršku odlučivanju (DSS), koji osiguravaju podršku za donošenje polustrukturiranih odluka, koristeći se modeliranjem i simulacijom, statističkim analizama, predviđanjem, modelima procjene investicija itd.

Svoju ulogu kontrole operacija koje se odvijaju unutar područja djelovanja menadžer uz podršku MIS-a obavlja gotovo rutinski, a u slučaju nastalih devijacija koristi se načelom MbE (*Management by Exception*).

Razina top menadžmenta definira odgovarajuće strategije za ostvarenje postavljenih ciljeva donoseći odluke koje su nestrukturirane, pa je stoga i uloga MIS-a na ovoj razini ograničena, posebno u obradi informacija. Međutim i na ovoj razini potreba za MIS-om postoji kako bi se došlo do informacija o okolini u kojoj hotelsko poduzeće djeluje. Karakteristike ovih operacija su specifične, a manifestiraju se u sljedećem:

- njihov je domašaj veoma širok
- to su pretežno agregirane informacije
- orijentacija im je na budućnost poduzeća
- učestalost prikupljanja je niska
- točnost im je mala

- ne ponavljaju se često
- kvaliteta ima prednost nad kvantitetom.

Posebna karakteristika ovih informacija je njihova multidimenzionalnost, što znači da one moraju respektirati različite aspekte strateških problema. Ako se komparira odnos između IS-a na strateškoj razini i IS-a na drugim razinama, tada će se uočiti bitne razlike koje rezultiraju iz činjenice da je IS strateškog menadžmenta prvenstveno orijentiran na okolinu. U tom smislu strateški menadžment mora razumjeti okolinu te predvidjeti ključne promjene, tendencije i utjecaje s njihovim odrazom na hotel.

Isto tako moraju se predvidjeti i „odazivi" hotela na utjecaj te okoline, što znači da se mora odabrati odgovarajuća strategija (ofenzivna, defenzivna, manevrirajuća ili druga). Da bi hotelsko poduzeće došlo do adekvatnih informacija o okolini, ono se koristi metodama skeniranja (Lucey, 1995, str. 21):

- neusmjereno skeniranje, koje karakterizira općenito istraživanje okoline, bez neke specifične svrhe
- uvjetovano skeniranje, koje se provodi pod utjecajem nekog povoda ili općenito iskustva menadžera
- neformalno usmjereno skeniranje, koje karakterizira aktivno snimanje specifičnih informacija ili informacija za specifične svrhe, ali na strukturiran i neformalan način
- formalno skeniranje, koje karakteriziraju specijalno oblikovane procedure ili sustavi traženja specifične informacije ili neke informacije o specifičnim problemima.

Treba naglasiti da se podatci o okolini ne prikupljaju samo u okolini već i u samom hotelu, gdje postoje brojni izvori, te da se ne odnose isključivo na ekonomske fenomene, već na sve segmente okoline.

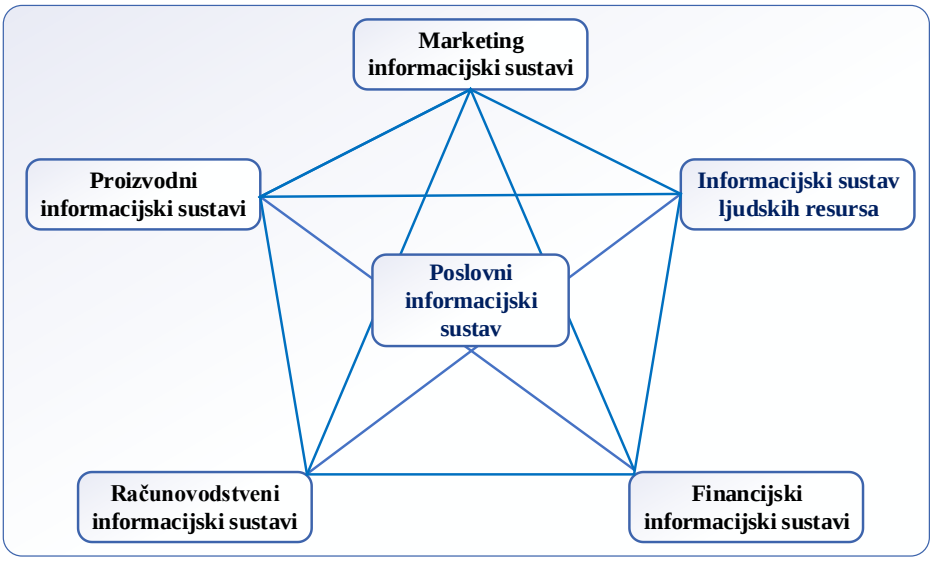
Operativne, taktičke i strateške odluke ostvaruju se posredstvom poslovnih funkcija poduzeća, koje svaka za sebe predstavljaju poseban informacijski podsustav. S tog se aspekta može govoriti da je MIS federacija informacijskih podsustava koji su oblikovani zato da podržavaju funkcijske jedinice poduzeća. Temeljni funkcijski informacijski sustavi su (O'Brien, 1999, str. 408-429):

1. Marketinški informacijski sustavi (engl. *Marketing Information Systems)* podupiru glavne funkcije marketinga, kao što su interaktivni marketing, automatiziranje operativne prodaje, menadžment proizvoda i prodaje, reklama i promocija, istraživanje i prognoziranje tržišta te usluživanje i potpora gostima.

2. Proizvodni informacijski sustavi (engl. *Manufacturing Information Systems*) podupiru funkcije proizvodnje. U tu svrhu u proizvodnom segmentu hotela obično je riječ o tri grupe sustava, a to su:
   - sustavi planiranja proizvodnih resursa (engl. *Manufacturing Resource Planning Systems*), koji uključuju predviđanje proizvodnje, raspored proizvodnje, planiranje potreba materijala, planiranje kapaciteta, kontrolu troškova proizvodnje i kontrolu kvalitete
   - sustavi izvođenja proizvodnje (engl. *Manufacturing Execution Systems*), koji uključuju radioničko planiranje i kontrolu, kontrolu strojeva, kontrolu robota i kontrolu procesa
   - sustavi inženjeringa (engl. *Engineering Systems*), koji uključuju CAD, CAE, planiranje procesa pomoću kompjutora, simulaciju proizvoda i izradu prototipa.
3. Informacijski sustavi ljudskih resursa (engl. *Human Resource Information Systems)* podupiru (1) planiranje potreba u ljudskim resursima, (2) razvoj zaposlenih do njihova punog potencijala i (3) kontrolu svih personalnih politika i programa. Tradicionalni HRIS se koristi za (1) obračun plaća i izvještavanje o plaćama, (2) održavanje personalnih podataka i (3) analizu korištenja ljudskih potencijala u poslovnim operacijama, da bi se danas dopunio (4) regrutiranjem, selekcijom i zapošljavanjem, (5) rasporedom posla, (6) analizom performansa (7) analizom beneficija zaposlenih, (8) obukom i razvojem te (9) zdravljem, sigurnošću i zaštitom.
4. Računovodstveni informacijski sustav (engl. *Accounting Information Systems)* najstariji je i najraširenij informacijski sustav u hotelijerstvu. On uključuje različite transakcijske sustave, od koji su najčešći obrada narudžbi, kontrola zaliha, dugovanja i potraživanja, plaće te financijski iskazi i izvještaji. Orijentacija mu je na planiranje i kontrolu poslovnih operacija, u koju svrhu ističe izvještaje o troškovima, razvoj financijskih budžeta i financijskih projekcija te analitičke izvještaje u kojima se komparira sadašnje s predviđenim stanjem.
5. Financijski informacijski sustavi (engl. *Financial Information Systems)* podupiru financijske menadžere u odlučivanju koje se odnosi na financiranje poslovanja i alokaciju te kontrolu financijskih resursa. Glavni podsustavi su mu menadžment gotovine (predviđanje i upravljanje gotovinom), investicijski menadžment (upravljanje kratkoročnim i drugim vrijednosnicama), kapitalno budžetiranje (vrednovanje rizika povrata kapitalnih izdataka) i financijsko planiranje (predviđanje financijskih performansi i financijskih potreba).

U okviru svake poslovne funkcije, odnosno svakog informacijskog podsustava, realno egzistiraju funkcionalne grupe poslova koje predstavljaju temeljna žarišta informacijskog sustava. Obično se nazivaju moduli s obzirom na to da se od njih polazi u dizajniranju informacijskog sustava, odnosno njihovim se uključivanjem ili isključivanjem dizajnira MIS. Ovi i drugi funkcijski informacijski sustavi povezuju se u jedinstveni poslovni informacijski sustav – PIS, kako je shematski predstavljeno narednim prikazom.

Slika 19. Sastavnice poslovnog informacijskog sustava



Izvor: prema O'Brien, *Introduction to Information Systems*, 1999, str. 430.

Kako se vidi, između pojedinih podsustava postoje složene veze koje čine cijeli MIS jedinstvenom cjelinom. Prekidi ovih veza uvjetuju disfunkcije u informacijskom sustavu, koje mogu uzrokovati donošenje potpuno neadekvatnih odluka s obzirom na deficit informacija. Funkcionalni podsustavi zahtijevaju aplikacije za izvršenje svih informacijskih procesa koji se u njima odvijaju, iako mogu biti povezani na zajedničku bazu podataka, bazu podsustava i bazu programa. Sve to treba pridonijeti učinkovitom funkcioniranju MIS-a, koji će osiguravati kvalitetne i promptne informacije uz najniže troškove.

1.14.2 Vrste poslovnih informacijskih sustava

Poslovni informacijski sustavi mogu se, s obzirom na temu razmatranja, klasificirati u tri temeljne grupe, i to: 1) operacijski informacijski sustavi, 2) menadžerski informacijski sustavi i 3) strateški informacijski sustavi, koji se u nastavku detaljnije pojašnjavaju.

1) ***Operacijski informacijski sustavi*** ili sustavi potpore operacijama (engl. *Operations Support System – OSS*) bavi se dnevnim operacijama u poduzeću. Operacijske su odluke kratkoročne prirode. Informacijski sustav koji podržava operacijske aktivnosti uglavnom prati transakcijske procese, rutinsko izvještavanje i potporu repetitivnom odlučivanju. Operativne sustave koriste nadglednici (prva linija menadžera), operatori i službenici. Kao potpora poslovnim operacijama koriste se:
   - sustavi poslovnih transakcija (engl. *Transaction Processing Systems – TPS*), koji prikupljaju i obrađuju podatke o tekućim transakcijama za potrebe korisnika; ovi podatci smješteni u bazama podataka mogu se koristiti i za potrebe sustava za potporu menadžmentu, a transakcije se mogu vršiti na dva načina – u *batch* obradi[2] ili u stvarnom vremenu (*online*) obradi.
   - sustavi kontrole procesa (engl. *Process Control Systems* – PCS), koji služe za nadgledanje i automatsko reguliranje procesa
   - sustavi suradnje u poduzeću (engl. *Enterprise Collaboration Systems* – ECS) takvi su informacijski sustavi koji koriste različite tehnologije za pomoć zajedničkom radu djelatnika; oni pomažu u komuniciranju ideja, podjeli resursa i koordinaciji napora djelatnika koji rade u timovima i drugim vidovima grupnog rada kako bi se ostvarili ciljevi poduzeća.
2) ***Menadžerski informacijski sustavi – MIS*** taktički su sustavi i bave se aktivnostima srednje razine menadžmenta, kao što su kratkoročno planiranje, organiziranje i kontrola. Menadžerski informacijski sustavi omogućuju naredne potpore (Turban, 1996, str. 51-52): statističko sumiranje, izvještaje o iznimkama, periodične i *ad hoc* izvještaje, komparativne analize, projekcije, rana upozorenja te rutinske odluke. S obzirom na to da u hotelskom poduzeću ima više razina i tipova menadžmenta, ova je potpora vrlo složen zadatak, koji se ne može ostvariti jednim informacijskim sustavom. Stoga je razvijeno i više sustava koji se

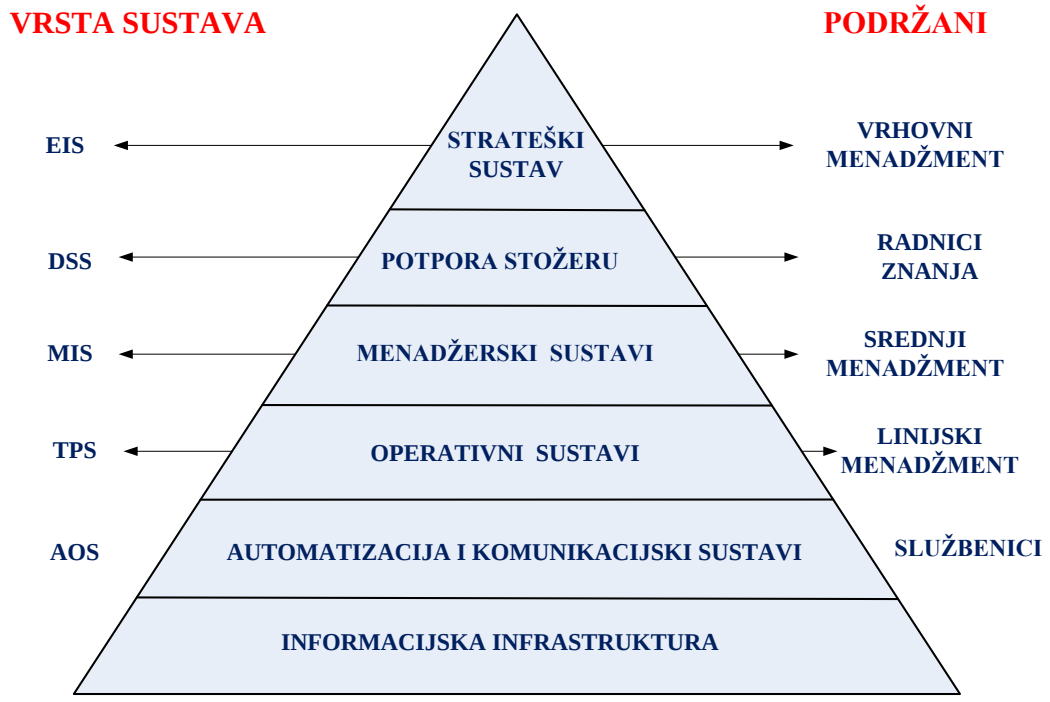
[2] *Batch Processing*, odnosno *batch* obrada jest obrada nekog cjelovitog zadatka (npr. obračun plaće), koji ne ovisi o odazivu nekog drugog računalnog sustava. *Batch* obrada ne omogućuje interakciju između korisnika i programa kada se program učita (unese) u računalo.

u osnovi razlikuju kao informacijski, a koji su namijenjeni srednjem i nižem menadžmentu te sustavi potpore odlučivanju, koji su namijenjeni vrhovnom menadžmentu.

3) ***Strateški informacijski sustavi*** bave se dugoročnim situacijama i odlukama koje značajno mijenjaju način na koji se poslovi obavljaju. Prvobitni strateški informacijski sustavi uključivali su samo dugoročno planiranje, dok suvremeni strateški informacijski sustavi pomažu menadžmentu da formulira strateški odgovor te da odabere odgovarajuću proaktivnu strategiju. Proaktivna strategija se sastoji u tome da poduzeće ne čeka na promjene, već da ih samo uvodi. Ovakve strategije su često podržane informatičkom tehnologijom u koju svrhu se može koristiti softver za generiranje ideja. Strateški IS-ovi koji su namijenjeni upravi hotelskog poduzeća nazivjua se i „izvršnima“ (engl. *Executive Information Systems – EIS*), a oblikovani su za strateške informacijske potrebe top menadžmenta. U tom smislu EIS treba osigurati selektirane informacije o ključnim čimbenicima, koji su kritični za ostvarenje strateških ciljeva hotelskog poduzeća.

Strateške odluke donosi vrhovni menadžment, a mogu biti poduprte putem EIS-a. Menadžerske odluke koje donosi srednja razina menadžmenta mogu se poduprijeti putem MIS-a. Konačno, operativne odluke koje donosi linijski menadžment i operatori mogu se poduprijeti putem TPS-a. Odnos između sustava potpore, menadžerskih razina i tipova odluka predočava se narednom slikom.

Slika 20. Odnos između sustava potpore, menadžerskih razina i tipova odluka



Izvor: obrada autora

Vrhovni je menadžment u hotelskom poduzeću malobrojan i on je lociran na vrhu piramide. Dodana razina potpore stožeru uvedena je između vrhovnog menadžmenta i menadžmenta srednje razine. Ovo je profesionalno osoblje (služba kontrolinga, financijski i marketinški analitičari), koje ima savjetodavnu ulogu u odnosu na vrhovni menadžment i menadžment srednje razine, a poduprti su s DSS-om, EIS-om i TPS-om. Većina ovih profesionalaca su radnici znanja (engl. *Knowledge Workers*) koji su odgovorni za otkrivanje ili razvoj eksternog znanja za poduzeće i njegova integriranja s postojećim informacijama, imaju ulogu savjetnika i konzultanata zaposlenicima te djeluju kao agenti promjena uvođenjem novih procedura, tehnologija ili procesa u poduzeće.

Druga skupina zaposlenih sastoji se od službenika (*clerical people*) koji podupiru sve menadžerske razine i razmješteni su na dnu piramide. Službenici su posebna grupa onih koji koriste, rukuju ili diseminiraju informacije. U hotelskom poduzeću to su voditelji recepcije, kuhinje, sale, nabave, održavanja, računovodstva, marketinga… Njih podupiru sustavi automatizacije i komuniciranja (OAS). Kada zaposlenici neke od opisanih razina rade u grupama (koje mogu biti funkcijske i međufunkcijske) poduprti su sustavima grupne potpore.

Povezivanjem različitih tipova informacijskih sustava s brojnim različitim ulogama formira se integrirani informacijski sustavi (IIS – *Integrated Information Systems*). Te se uloge obično u praksi integriraju u kombiniran ili međufunkcijski informacijski sustav, koji je oblikovan uglavnom da producira informacije i podupire donošenje odluka različitih razina menadžmenta i različitih funkcijskih jedinica.

1.15 Značajke informatizacije hotelskog poslovanja

Ulazak informatike u hotelsko poslovanje više je bio posljedica zbivanja na globalnom turističkom tržištu nego namjera hotelske industrije da prati trendove poslovnih subjekata u drugim granama i djelatnostima. Naime, dugo se smatralo da je klasični marketing više nego dovoljan, a da je hotelska klijentela zauvijek vjerna i lojalna. Širenjem turističke ponude i potražnje, nastupile su promjene na turističkom tržištu. Protekom vremena sve je manje klasičnih, statičnih turista koji su svoj odmor provodili „svake godine u isto vrijeme u istom mjestu“. Trendovi ukazuju kako suvremeni turisti žele u svom aktivnom odmoru posjetiti najmanje dvije, a mnogi i više destinacija. To znači da se u destinacijama zadržavaju kraće

vrijeme, a itinerar koji su im nudile turističke agencije izrađuju sami neposrednom interakcijom koju im omogućuju brojne računalne, odnosno mobilne aplikacije.

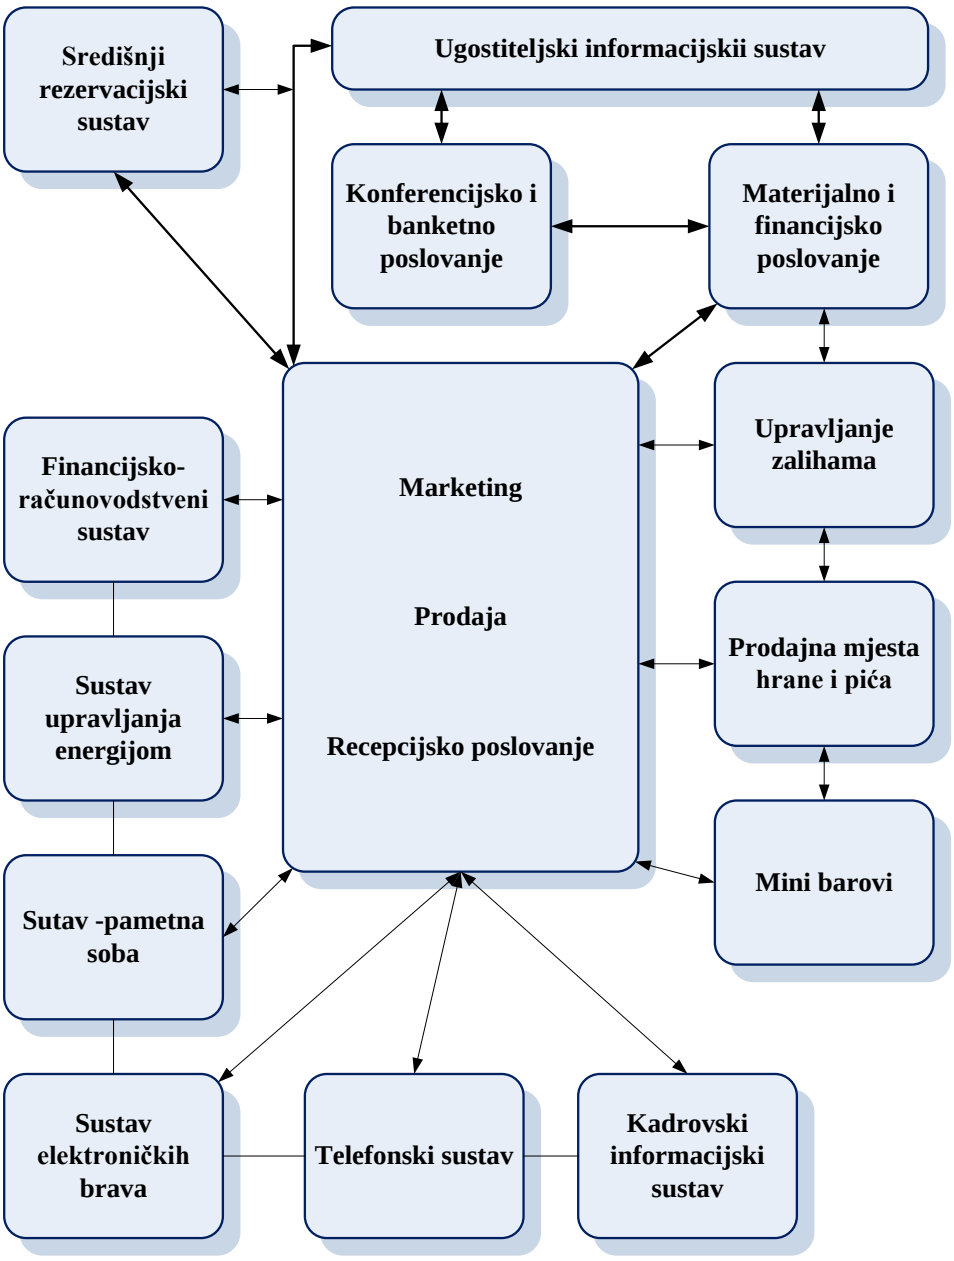
Hotelska poduzeća prihvatila su informatizaciju kao prednost, ali i potrebu, najprije u sustavu rezervacija, a potom i u svim odjelima hotela. Promjene koje su nastupile prihvaćanjem informacijske tehnologije u svojem poslovanju odrazile su se na sve segmente upravljanja poslovanjem, objektima (pametni hoteli) i odnosima s gostima.

Integralni hotelski informacijski sustav je program koji informatički objedinjuje procese i aktivnosti proizvodnje, pružanja usluga, marketinga i upravljanja hotelom. Svrha integriranog sustava je pravovremena i učinkovita razmjena informacija svih segmenata poslovanja s ciljem da se pruži podrška menadžerima u planiranju, kontroli, upravljanju i odlučivanju. Galičić i Šimunić (Galičić & Šimunčić, *Informacijski sustavi i elektroničko poslovanje u turizmu*, 2006, str. 132) navode bitna obilježja hotelskog integralnog informacijskog sustava:

- sustav treba biti sveobuhvatan, tako da obuhvati sve poslovne procese i službe u hotelu
- sustav treba biti složen od modula koji pokrivaju sve segmente poslovanja hotela te da svaki modul može funkcionirati neovisno od ostalih modula
- sustav treba biti kvalitetan i pouzdan
- sustav treba biti otvoren za nadogradnju, a aplikacijska rješenja moraju paralelno egzistirati i razmjenjivati podatke sa rješenjima nekih drugih proizvođača
- mora biti prilagodljiv raznim tipovima i veličinama poduzeća i načinima organizacije poslovanja u njima (otvorenost sa stanovišta organizacijskih rješenja)
- sustav mora biti razvojan na način da u njegovu razvoju, pored vlastitih, učestvuju i vanjski stručnjaci te sami korisnici (rukovoditelji, tehnolozi i operateri), čime se u jednom timskom i interdisciplinarnom radu ostvaruju vrhunski rezultati.

Shematski prikaz integralnog hotelskog sustava, kako su ga prezentirali Galičić i Šimunčić (*Informacijski sustavi i elektroničko poslovanje u turizmu*, 2006, str. 131), predočava se narednom slikom.

Slika 21. Integralni hotelski informacijski sustav



Izvor: prema Galičić i Šimunčić, 2006, str. 131.

Integralni hotelski informacijski sustav (kako je predočen na predočenoj slici), njegova primjena i učinkovitost korištenja, predmet je istraživanja provedenog među dobrim poznavateljima hotelskog sustava, o kojem će biti više rasprave u empirijskom dijelu rada.

POSLOVNA INTELIGENCIJA KAO NOVA PARADIGMA INOVIRANJA KONCEPCIJE RAZVOJA HOTELSKOG PODUZEĆA

Sustavi za upravljanje informacijama (engl. *Management Information Systems* – MIS) cijeli su niz godina predstavljali učinkovitu podršku menadžmentu u različitim zadatcima. Takvi postojeći IT sustavi zbog sve većih zahtjeva korisnika više ne mogu ispunjavati njihova očekivanja pri donošenju poslovnih odluka, kao što su (Olszak & Ziemba, 2007, str. 137):

- promptno donošenje odluka
- analiziranje konkurencije
- praćenje više podataka s različitih stajališta
- permanentno analiziranje brojnih podataka i nuđenje različitih varijanti.

Postojeći sustavi ne mogu na pravi način omogućiti integraciju različitih, isprepletenih i raznorodnih podataka i učinkovito interpretirati takve podatke u širem kontekstu. Nadalje, oni ne mogu otkriti međuzavisnosti podataka. Posljedica je to nepravilne tehnike prikupljanja, nepotpune analize, otkrivanja i vizualizacije podataka.

Kako bi hotelska poduzeća mogla odgovoriti izazovima dinamičnog turističkog tržišta, ona bi trebala stalno nadograđivati postojeće sustave i po potrebi ih zamijeniti. Suvremeno je unaprjeđenje, odnosno nastavak, poslovna inteligencija (engl. *Business Intelligence* – BI). Potreba za skladištenjem podataka kao pretraživač, napredak u filtriranju podataka, veće mogućnosti hardvera i softvera, zajedno sa razvojem mrežnih tehnologija koje pruža korisničko sučelje, kreiraju bogatije okruženje za poslovnu inteligenciju.

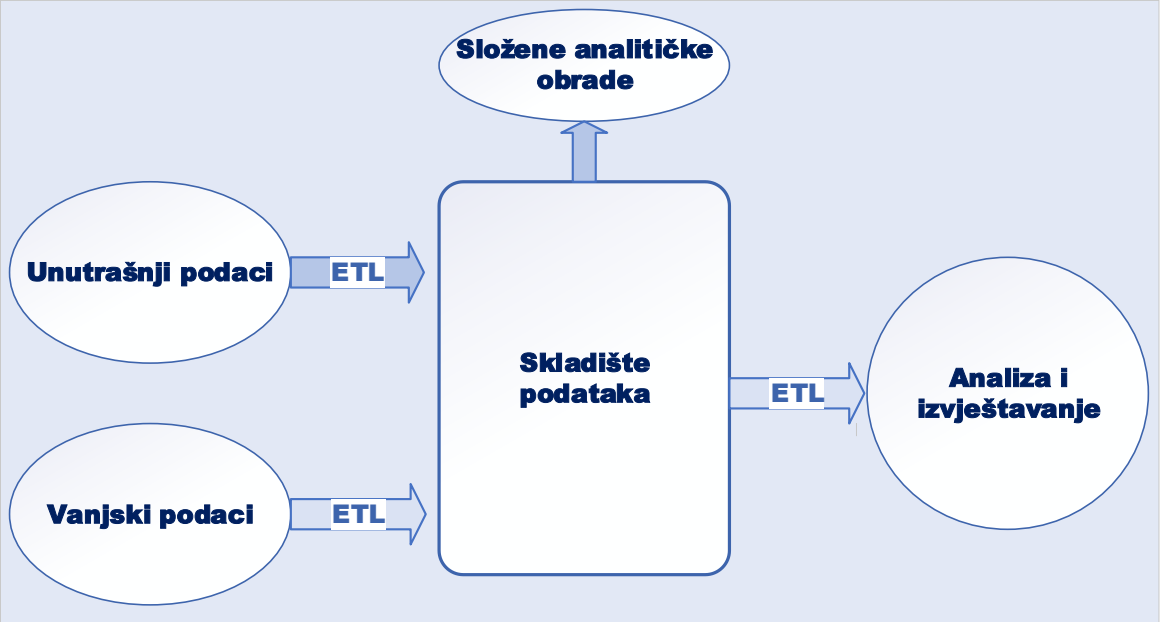
1.16 Odrednice poslovne inteligencije

Pojam „poslovna inteligencija" najčešće je korišten u obliku engleskog naziva *Business Intelligence* – BI. U literaturi se još pojavljuju inačice „poslovno izvještavanje", „poslovno istraživanje", kao i „upravljanje poslovnim informacijama". Poslovna inteligencija podrazumijeva široko područje aplikacija i tehnologija za prikupljanje, skladištenje i analiziranje podataka, čija je svrha donošenja poslovnih odluka. Poslovna je inteligencija računalna podrška pri donošenju odluka, a može se definirati kao "korištenje svih potencijalnih podataka i informacija radi donošenja poslovnih odluka i u skladu s tim prepoznavanje novih poslovnih mogućnosti" (Ćirić, 2006). Poslovna je inteligencija tehnološka infrastruktura koja

daje podrška svim poslovnim funkcijama pri upravljanju raspoloživim informacijama. U praksi ona predstavlja računalnu podršku u procesu donošenja poslovnih odluka.

Pojednostavljeno se može zaključiti kako je funkcija poslovne inteligencije da procesuira prikupljene interne i eksterne podatke te ih pretvara u zahtijevane informacije kao podršku poslovnom odlučivanju, kao što je to predočeno narednom slikom.

Slika 22. Sustav poslovne inteligencije



Izvor: Panian, Ž., Klepac, G.: *Poslovna inteligencija*, Masmedia, Zagreb, 2003., str. 61.

Kao temeljne karakteristike poslovne inteligencije Panian i Klepac *(Panian & Klepac, Poslovna inteligencija,* 2003, str. 24) izdvajaju individualizaciju, proaktivnost i operativnu genezu:

- individualizacija znači da će procesuirani podatci proizvesti informaciju „na zahtjev“ onih kojima je ta informacija potrebna za rješavanje problema i donošenje odluka
- proaktivnost označava automatizam kod formiranja informacija; iako se informacije kreiraju u realnom vremenu i aktualne su u trenutku promatranja, njihova proaktivnost se ogleda u činjenici da se na temelju njih može donijeti odluka koja će prevenirati neke događaje u budućnosti
- operativna geneza znači da se informacija temelji na aktualnim operativnim podatcima.

Promatrano s aspekta hotelskog menadžmenta, primjerice kod donošenja odluke o investiranju u proširenje smještajnih kapaciteta, zahtjev podnosi investicijski (financijski) menadžer, traži stanje raspoloživih sredstava, uvjete financiranja iz vlastitih ili kreditnih izvora, visinu kamata i najpovoljnije rokove otplate. Dobiva informacije o mogućim izvođačima, formiranju ponude i optimalnim uvjetima dovršenja radova (do početka sezone ili sl.). Sve je to moguće ako BI raspolaže operativnim podatcima: financijskim, stanjem resursa i planovima razvoja.

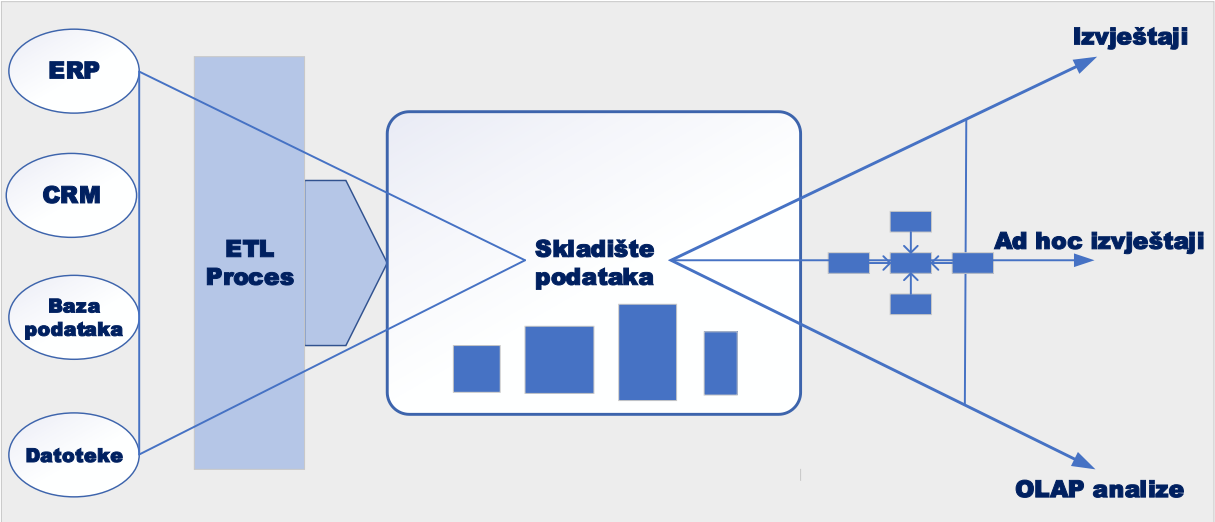
Što se više podataka nalazi u bazama BI sustava to će i dobivene informacije (preporuke) biti točnije. Veliki poslovni sustavi, posebice oni čije su poslovne jedinice disperzirane u više država, prihvatili su model BI-a, uvidjevši da dobivaju potrebne informacije daleko brže i da te informacije nisu pod subjektivnim utjecajem podnositelja, već su produkt računskih operacija.

BI raspolaže alatima kojima povezuje menadžere, partnere, dobavljače i krajnje korisnike. Omogućuje menadžerima da upravljaju, pregledavaju, uspoređuju velikim i složenim podatcima korištenjem računalnih programa – modula, prilagođenih njihovim zahtjevima i potrebama. Sustavi BI-ja raspolažu trima osnovnim modulima:

1. modul za zahtjeve čine programski paketi koji omogućavaju korisnicima pitanja o matricama ili detaljima u podatcima
2. modul rudarenja podataka (engl. *Data Mining*) alat je za računalno pretraživanje karakterističnih matrica ili korelacija iz baza podataka
3. modul za *online* višedimenzionalne analize (engl. *Online Analytical Processing* – OLAP) koji omogućuje menadžerima da dobiju na uvid širok raspon podataka s različitih stajališta i dimenzija.

Infrastruktura poslovne inteligencije prema *ComputerWeekly* predočava se narednom slikom.

Slika 23. Infrastruktura poslovne inteligencije



Izvor: *Build open source business intelligence platform successfully*, https://www.computerweekly.com/tip/Build-open-source-business-intelligence-platform-successfully

Kako bi sustav poslovne inteligencije mogao ispunjavati zahtjeve korisnika, potrebno je da oni nedvosmisleno naznače obilježja i vrste informacija koje zahtijevaju te njihovu učestalost i sredstva komunikacije putem kojih će im informacije biti prezentirane.

1.16.1 Značaj poslovne inteligencije u funkciji anticipiranja koncepcije razvoja hotelskog poduzeća

Svoju primjenu u hotelskoj industriji poslovna inteligencija najčešće nalazi u projektima razvoja, kada se donose odluke temeljene na procjenama nekog budućeg stanja ovisnog o brojnim faktorima različitog smjera i intenziteta djelovanja. Da bi procjena nekog budućeg stanja bila što pouzdanija, potrebno je poznavati i koristiti podatke iz interne i eksterne okoline pohranjene u bazama podataka. Što je količina i kvaliteta ulaznih podataka veća, to je i rezultat višekriterijske analize pouzdaniji. Menadžeri – korisnici PI-a, koji imaju kontrolu nad svim informacijama, nalaze se u prednosti u odnosu na konkurenciju te mogu donositi pravovremene i kvalitetne poslovne odluke. Poslovna inteligencija u hotelskom poslovanju svoju primjenu nalazi u svakodnevnim procesima upravljanja nabavom, upravljanja zalihama, upravljanju kvalitetom, upravljanju energijom, potrošnjom vode i sl. Navedeni se procesi odvijaju automatizmom prema zadanim parametrima, ali njihove analize predstavljaju važne informacije o potrebama mijenjanja pojedinih parametra u funkciji bolje iskoristivosti, ušteda poboljšanja kvalitete itd.

1.16.2 Poslovna inteligencija u sinergijskom efektu novih strateških usmjerenja hotelskog poduzeća

Temeljna je prednost korisnika sustava PI-a raspoloživost kvalitetnih informacija potrebnih za donošenje poslovnih odluka. Učinak korištenja PI-a prvenstveno se ogleda u skraćivanju vremena potrebnog za izradu izvještaja, a time i povećanje raspoloživog vremena za analizu. Menadžerima su na ekranu računala stalno dostupni svi parametri poslovanja hotela u stvarnom vremenu, što pruža mogućnost korekcija pojedinih procesa, ali i strateških promišljanja o usmjerenju hotelskog poduzeća.

Zadovoljstvo korisnika sustava PI-a bit će upravno proporcionalno zadovoljstvom zahtijevanim karakteristikama PI-a s obzirom na hotelsko poslovanje. Panian i Klepec (2003, str. 215) navode sljedeće zahtjeve:

- sigurnost sustava, koja podrazumijeva zaštitu podataka od neovlaštenog pristupa i korištenja
- dostupnost sustava, koja podrazumijeva raspoloživost u svakom trenutku neovisno o mjestu pristupa i komunikacijskog kanala
- adaptabilnost na promjene u poslovnom okruženju
- mogućnost pohrane velike količine podataka i njihovu nadogradnju
- jednostavnost pristupa informacijama i jednostavnost izvještaja.

Navedeni su samo opći zahtjevi, koji su uglavnom već standardni, a korisnici ih nadopunjuju prema svojim potrebama.

1.16.3 Pametni turizam

Pametni turizam (engl. *Smart Tourism*) suvremeni je pomodni izraz (engl. *buzzword*) nastao kako bi se najlakše opisala integracija tehnologije, informatike, razmjene podataka i umjetne inteligencije u funkciji upravljanja turističkim kretanjima (Gretzel, Sigala, & Xiang, 2015, str. 179). Pojam „pametan“ (engl. *smart*) postao je poštapalica za mnoge usluge i proizvode pa tako postoje: pametni gradovi, pametni telefoni, pametne ploče…, a svi se oni koriste kako bi pomagali korisnicima, usmjeravajući ih prema željama davatelja usluge. U prometu će usmjeravati vozača na manje opterećene prometnice, u gradovima će usmjeravati na slobodna parkirališta, ali i na slobodna mjesta u restoranu, dostupnost kino ulaznica, kao i obavještavati o sportskim rezultatima, koncertima. Usluge „pametnih gradova“ dostupne su besplatno, a korisnik će sam odbrati koje informacije želi primati.

Većina tehnološki naprednih proizvoda veže uz sebe pojam „pametno“, pa tako postoje pametni telefon, pametna kartica, pametni televizor itd., koji označavaju multifunkcionalnost i visoke razine povezanosti. U kontekstu tržišta prisutna je pametna ekonomija, koja se odnosi na tehnološki podržane nove oblike suradnje i stvaranje vrijednosti koje vode inovacijama, poduzetništvu i konkurentnosti. Osnovne su razlike između elektroničkog i pametnog pristupa turizmu sistematizirane u narednom prikazu.

Slika 24. Razlike između elektronskog i pametnog turizma

	e-Turizam	Pametni Turizam
Područje	digitalno	Povezano digitalno i fizičko
Tehnologija	Web mjesta	Senzori i pametni telefoni
Faze putovanja	Prije i poslije putovanja	Za vrijeme putovanja
Podaci o gostu	Informativni	Velike baze podataka
Paradigma	Interaktivnost	Tehnološka medijacija kreiranja
Struktura	Lanac vrijednosti/posrednici	Eko sustav
Razmjena	B2B, B2C, C2C	Javno-privatno-korisnička suradnja

Izvor: prema Hwang, et al., *Constructivism in Smart Tourism Research : Seoul Destination Image* 2015, str.164

U kontekstu turizma, „pametno“ se koristi za opisivanje kao amalgam svega navedenog. Postoji snažna institucionalna podrška, a u nekim slučajevima čak i pritisak da se ostvari pametni turizam. Posebno su u Aziji usuglašeni napori da se potakne program pametnog turizma. Vlade u Kini i Južnoj Koreji uglavnom su usredotočene na inicijative za financiranje tehnološke infrastrukture koja podržava pametni turizam (Hwang, Park, & Hunter, 2015, str. 164).

1.17 Prilagodba hotelskog poduzeća politici novih tržišnih vrijednosti

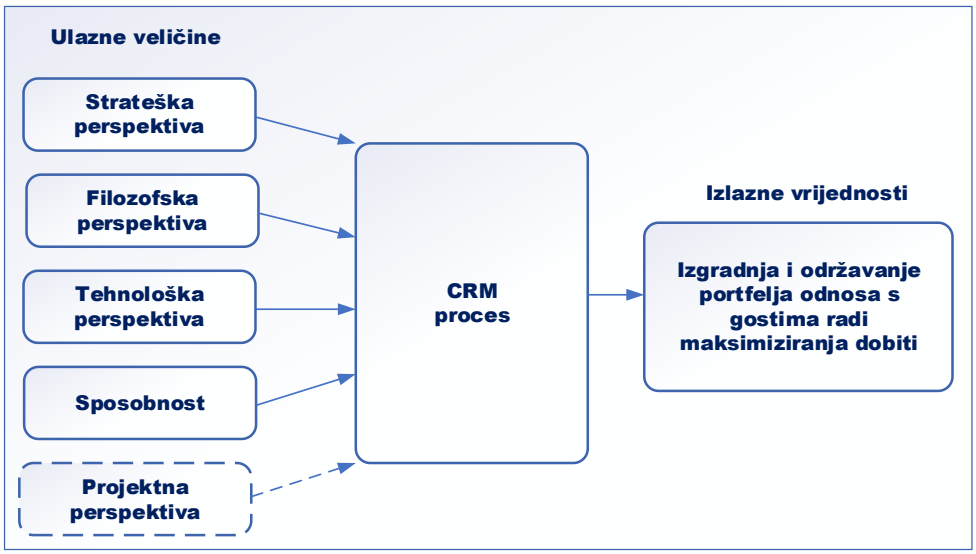
Tržišna vrijednost nekog hotelskog poduzeća jednaka je vrijednosti njegove materijalne i nematerijalne imovine. Kao najvažniju nematerijalnu imovinu literatura navodi vrijednost brenda, odnosno marke koju neki hotel nosi. Međutim suvremeni trendovi na turističkom tržištu ne jamče poznatim brendovima uspjeh na tržištu samo zato što imaju brend sa stoljetnom tradicijom, vrhunsku uslugu i ponudu. Suvremeni gost, ma koliko lojalan bio nekom brendu, može jednom objavom na društvenim medijima prouzročiti značajnu štetu. To posebice ako se radi o društveno osjetljivoj problematici, poput iskorištavanja maloljetne radne snage, lošeg odnosa prema okolišu, nezbrinjavanju otpada, kao i prekomjernom trošenju vode i energije.

U tom je smislu bitno da menadžeri hotelskog poduzeća, pored provođenja društveno odgovornog poslovanja, održivog razvoja i iskazivanja brige za okoliš, prate trendove razvoja informacijske tehnologije, posebice u komunikacijskoj interakciji s gostima. CRM u tim procesima preuzima ključnu ulogu jer se korektnim segmentiranjem gostiju stvaraju dugoročno prijateljski odnosi s gostom i prepoznaju gosti lojalni brendu, koji su ujedno i najbolji promotori.

Kako bi se prilagodili, odnosno uskladili s informacijskim okruženjem i zahtjevima koje informatika postavlja pred menadžment kako ne bi zaostajao za konkurencijom, potrebno je realno sagledati perspektivu CRM-a sa strateškog, filozofskog i tehnološkog aspekta, kao i

sposobnosti vlastitog poslovnog sustava. Narednom slikom predočava se teorijski okvir perspektive CRM-a

Slika 25. Teorijski okvir perspektive CRM-a



Izvor: prema Zerbino, Aloini, Dulmin, i Mininno, *Big Data-enabled Customer Relationship Management: A holistic approach*, 2018, str. 824.

Strateška perspektiva ima za cilj usmjeriti CRM za ostvarivanje veće dobiti hotelskog poduzeća, uvažavajući pritom želje i zahtjeve gostiju s mogućnostima hotela. Raspodjela sredstava za izgradnju i održavanje odnosa mora dosljedno vrednovati stalne goste u odnosu na one nove.

Filozofska perspektiva kontira potrebu za usredotočenje na gosta kao jednim od glavnih resursa za CRM. Promjene u razmišljanju, organizacijskoj strukturi i općenito poimanju poslovanja su neizbježne prihvaćanjem CRM -a. To uključuju nove procese i postupke koje treba primijeniti, promjene u ponašanju zaposlenika, odnosno provesti reinženjering poslovnog procesa – BPR.

Tehnološka perspektiva sugerira da alati CRM-a doprinose poboljšanju dugoročnih odnosa s gostima hotela. Uspjeh CRM-a zavisi o stupnju korelacije između tehnologije, procesa proizvodnje usluge, kvalitete usluge, zaposlenika hotela i gosta.

Promatrano iz perspektive sposobnosti sustava, sugerira se da hotelsko poduzeće posjeduje skup sinergističkih resursa, odnosno sposobnosti za usvajanje spoznaja o gostima i mogućnosti da ih primjene. Sposobnost sustava podrazumijeva upravljanje spoznajama o gostima, da posredstvom CRM-a gradi i održava dugoročne odnose, s ciljem maksimiziranja dobiti. Kako

bi se precizirale relevantne aktivnosti upravljanja informacijama, poduzeće bi trebalo koristiti odgovarajuće IT alate i aplikacije.

UPRAVLJANJE ODNOSIMA S GOSTIMA – FUNKCIJA INTEGRIRANOG INFORMACIJSKO-KOMUNIKACIJSKOG SUSTAVA HOTELSKOG PODUZEĆA

Razvojem društvenih odnosa gospodarstva općenito širi se i problematika hotelske industrije u svim oblicima poslovanja. Tako je usporedno s evolucijom informacijske znanosti i komunikacijskih tehnologija došlo do intenzivnog razvoja ***upravljanja odnosima s gostima*** u hotelijerstvu. Od svih prednosti e-poslovanja koje se nude u hotelskoj industriji, svakako je najznačajnija mogućnost da se u realnom vremenu pristupa informacijama iz cijelog svijeta. Internet kao globalna mreža nudi podršku nizu funkcija i procesa u hotelskom poduzeću s ciljem razvoja proizvoda i pružanja usluga za gosta. Nadalje, internet predstavlja moćan komunikacijski medij kojim se učinkovito mogu povezivati hotel i gost kao davatelji i primatelji usluge. Internet omogućuje njihovu komunikacijsku interakciju, a prateća računalna tehnologija bilježenje, procesuiranje i analitiku njihove korespondencije kao osnovice upravljanja odnosima s gostima.

S obzirom na to da hotelijerstvo predstavlja infrastrukturnu osnovicu turizma i putovanja u širem smislu, nužno je stoga upravljanje odnosima s gostima u hotelijerstvu tržišno promatrati u kontekstu tih pojava. Kategorija e-poslovanja u hotelijerstvu na široj je svjetskoj razini, a time i u nacionalnoj hotelskoj industriji u stalnoj progresiji.

Upravljanje odnosima s hotelskim gostima inačica je CRM-a prilagođena hotelskim sustavima i dostupna je u različitim verzijama, od internetskih poslužitelja do specijaliziranih softverskih paketa.

1.18 Općenito o upravljanju odnosima s gostima

Postoji više definicija upravljanja odnosa s kupcima koje se suštinski ne razlikuju i ovise o stajalištu autora i njegovu viđenju tih odnosa. Uglavnom postoji konsenzus kako je CRM kombinacija (simbioza) poslovnih procesa i tehnologije, koji ima za cilj razumjeti različite interese čimbenika odnosa pružatelja i korisnika usluge. Ovako postavljena definicija korisna

je za razlikovanje konkurentnosti proizvoda od usluga (Al-Shammari & Mallouh, 2012). Sa stajališta marketinga, upravljanje odnosima s kupcima strateški je poslovni pristup koji se temelji na teoriji marketinga odnosa. Ona je definirana kao „postupak stjecanja, zadržavanja i partnerstva sa selektivnim kupcima radi stvaranja vrhunske vrijednosti za tvrtku i kupca“ (Parvatiyar & Sheth, *Customer relationship management: Emerging practice, process, and discipline,* 2001, str. 6).

Korištenjem računalne tehnologije CRM je evoluirao u elektroničko upravljanje odnosima s kupcima, gdje se tehnologija koristi za služenje i ostvarenje želja kupaca, čime se ostvaruje dodana vrijednost (Fjermestad & Robertson Jr, 2016).

1.18.1 Uloga informacijske tehnologije u upravljanju odnosima s kupcima

Informacijska tehnologija nezaobilazni je čimbenik povezivanja svih subjekata u turističkom lancu ponude i potražnje. Ona je kanal interakcije koji je već desetljećima prisutan, počevši od rezervacijskog sustava CRS-a (engl. *Computer Reservation System*), najprije u zračnom prometu, a potom u turističkim agencijama i hotelima, da bi se došlo do toga da gotovo svaki iznajmljivač apartmana koristi neku od aplikacija upravljanja rasporedom iznajmljivanja.

Uvođenjem globalnog distributivnog sustava GDS-a (engl. *Global Distribution System*) 80-ih godina prošlog stoljeća započela je era elektroničkog turizma (e-turizma), koja se sustavno nadograđuje, a pojavom širokopojasnog interneta 3G, 4G pa i 5G, mobilne mreže čine prijenos podataka dostupnim „uvijek i svagdje“.

Usporedno s razvojem e-turizma razvijale su se u teorije o prednostima poput „interaktivnosti, fleksibilnosti, jednostavnosti obavljanja transakcija, veće mogućnosti odabira turističkih ponuda, dostupnosti informacijama“ (Nusair & Kandampully, 2008, str. 9), ali i nedostatcima poput „slabe razine znanja i stručnosti, kao i uvjeta za primjenu IT-ja u malim i srednjim poduzećima“ (Boshof & Elliot, 2005, str. 50).

1.18.2 Internet u funkciji razvoja odnosa s klijentima u turizmu

Upravljanje odnosom s klijentima koncept je koji je svoj procvat doživio upravo u vrijeme eksponencijalnog razvoja interneta. Mogućnost efikasnog ostvarenja direktnog i ciljanog kontakta s klijentima koji je internet pružio donijela je sa sobom posljedicu da su tvrtke po prvi put mogle na profitabilan način pristupiti izgradnji personaliziranog odnosa sa svakim svojim klijentom i putem toga povećati svoju prodaju kroz *cross-selling* i *up-selling* alate, a ujedno i povećati zadovoljstvo svojih klijenata.

Učinkovitost korištenja interneta u turističke svrhe temelji se na kvalitetnom korištenju resursa. Samo kvalitetno upravljanje tehničkim, informacijskim i ljudskim resursima može doprinijeti zadržavanju i unaprjeđenju konkurentske prednosti turističkog poduzeća. Dostupnost interneta, GPS-a i pametnih mobilnih uređaja širokom krugu turista upotpunjuje njihov doživljaj, orijentaciju u prostoru, ali i povezanost s ishodištem, što omogućuje bezbrižnost i potpunu posvećenost turističkom doživljaju. Ponuditelj pak putem odgovarajućih aplikacija pruža jednostavnost usluge organizacije putovanja, rezervacija, odabira prijevoznog sredstva, smještaja, prehrane te u konačnici smanjenje operativnih troškova zaposlenika, s obzirom na to da se prodaja odvija preko interneta (Yoo, Lee, & Park, 2010, str. 90).

Međutim sama primjena učinkovitosti tehnoloških aplikacija u turizmu zavisit će o, kako navode Bilgihan i dr. (2011, str. 142), „1) usklađenosti poslovne strategije i primjene IT rješenja, 2) vrsti IT aplikacija, 3) mogućnosti primjene IT-ja, 4) raspoloživim financijskim sredstvima i 5) načinima donošenja odluka u hotelima, kao i u drugim poduzećima u turizmu“.

Promjene koje u turističkom poslovanju donosi internet odražavaju se i na promjene u marketinškom pristupu. Turistički proizvod kao element klasičnog marketinškog miksa sve se više zamjenjuje elementom „dinamični paket usluga“, koji pruža sve s čime se suvremeni turist koristi u svrhu zadovoljenja svojih potreba (Middletion, Fayll, Morgan, & Ranchhod, 2009, str. 268).

Dinamični paket usluga obuhvaća *online* rezervacije u transportu, smještaju, prehrani, posjetima raznim događanjima, *rent-a-cara*, kino ulaznica, pa sve do rezervacija u frizerskim salonima i sl. Turističke agencije aktivno surađuju sa svim davateljima usluga u dinamičnom paketu promovirajući ih svojim aplikacijama i mrežnim stranicama, nazočnošću na Facebooku i sl.

1.19 Primjena e-marketinga u hotelijerstvu

Marketing je pokretač *weba*, a *web* je pokretač e-marketinga – tako može glasiti sintagma o interakciji *weba* i marketinških aktivnosti na *webu*. Možda *web* izvorno i nije osmišljen da odašilje marketinške poruke, ali, kada je jednom postavljena, mrežna stranica nekog poslovnog subjekta šalje i neku marketinšku poruku. Kako je odmakom vremena mrežni prostor postajao sve dostupniji, a izrada mrežnih stranica omogućena svima s osnovama informacijske pismenosti, tako je i e-marketing postao alat širokog broja korisnika koji o marketinškim postulatima i nisu imali dovoljno spoznaja, što je pak dovelo do „šarenila“ poruka koje nisu polučile željene rezultate.

Turistička djelatnici diljem svijeta prepoznali su *web* kao kanal za odašiljanje poruka širokom krugu korisnika, a postavljanjem „brojača klikova“ postalo je vidljivo koliko je „posjetitelja“ pregledalo mrežnu stranicu i koliko dugo se zadržalo na stranici.

Zakupljeno *web* mjesto (engl. *site*) nije vezano samo uz mrežnu stranicu, već omogućuje pretraživanje i interakciju s „posjetiteljem“ upotrebom e-pošte, *chata*, bloga, foruma za *online* rasprave i analize konkurencije. Mrežno mjesto time doprinosi modelu *online* marketing odnosa (engl. *e-relationship marketing*) u poslovanju (Timm, 2011, str. 22).

Važne značajke mrežnog mjesta o kojima ovisi njihovo pregledavanje i interakcija su sigurnost, sadržaj, dizajn, jednostavnost korištenja i dostupnost. Ako neki od ovih elemenata nije zadovoljen, posjetitelj napušta stranicu i u mnoštvu sličnih odabire drugu. Prema Buhalis i Law (2008, str. 613) osnovne funkcije mrežnog smjesta za turističke djelatnosti su:

- dekorativna funkcija, koja se koristi za iznošenje općih informacija kojima se prezentira turistički subjekt
- informativna funkcija, koja je namijenjena ciljanim korisnicima (kupcima ili investitorima)
- interakcijska funkcija, koja je usmjerena na razvoja odnosa s kupcima (uz pomoć i podršku mrežnih tehnologija i raznih društvenih platformi).

Web dizajn kod turističkih poslovnih subjekta trebao bi predstavljati vizualan doživljaj za posjetitelja koji ima i emotivnu dimenziju, s namjerom da izazove pozitivne reakcije posjetitelja te da mu pruži željene informacije.

1.19.1 Subjekti e-marketinga u hotelijerstvu i turizmu

E-marketingu hotelijerstvu i turizmu predstavlja nesumnjivo temeljnu stratešku odrednicu poslovanja poduzeća iz sektora turizma. Ulazak poduzeća u marketinške projekte na internetu relativno je jeftin i lak pa tisuće poduzeća i poslovnih ljudi iz područja turizma svakodnevno predstavljaju svoje mrežne stranice u svijet interneta.

Prema Kotleru (2010:11), glavne industrije koje pokrivaju turizam jesu industrije hotelijerstva, ugostiteljstva i putovanja. Međuzavisnost ove tri industrije sve je jača i čini se da će tako i ostati. Uspješan marketing u hotelijerstvu i ugostiteljstvu snažno ovisi o industriji putovanja, što znači da se marketinškim djelovanjem na jedan industrijski sektor, namjerno ili ne, promoviraju i ostala dva. Danas nije moguće uspješno predstaviti neki hotel ako se ne spomene ugostiteljska ponuda, kao i najbolji i najudobniji način dolaska i odlaska iz tog hotela. To je posebice došlo do izražaja u *web* promociji. Naime, na svakoj boljoj mrežnoj stranici hotela postoje poveznice (linkovi) koji upućuju na restorane, turoperatore i zrakoplovne, željezničke, autobusne taksi veze. Isti je slučaj s mrežnim stranicama restorana, turoperatora ili turističkih organizacija, koji poveznicama upućuju na hotele u okruženju. Stoga je, kada je riječ o e-marketingu, moguće koristiti zajednički pojam koji povezuje sve navedene industrije, a to je turizam.

Subjekti koji čine okosnicu e-marketinga u turizmu, prema Andrliću (2007:86), jesu:

- turističke agencije odredišta (engl. *Destination Management Organisations* – DMO)
- usluge smještaja – hoteli, hosteli, aparthoteli
- ugostiteljske usluge (engl. *Hosptality Services*)
- putničke agencije (engl. *Travel Agencies*)
- turoperatori (engl. *Tour Operators*)
- turističke atrakcije (engl. *Visitor Attractions*).

Nabrojani subjekti pretpostavljaju posjedovanje vlastitih mrežnih stranica. Stoga se mrežna stranica može promatrati kao nositelj e-marketing aktivnosti u turizmu.

Internet preko svojih mnogobrojnih servisa pruža turističko-ugostiteljskim subjektima mnoge konkurentske mogućnosti, s obzirom na to da se tijekom posljednjeg desetljeća u turističkoj industriji dogodila snažna internacionalizacija turističkih tržišta sa svakodnevnim fluktuiranjem novih i postojećih konkurenata. Jedan od razloga takvoj situaciji je i snažni razvoj interneta, koji pruža trenutačan i uvijek otvoren pristup informacijama u cijelom svijetu.

Poslovanje u hotelijerstvu zbog izuzetno promjenljivog i kompleksnog okruženja sve je teže bez djelotvornog marketinškog promišljanja i planiranja strategija. Potrebno je naglasiti da tehnološki napredak i njegova primjena predstavlja ključni čimbenik u stvaranju konkurentske prednosti u suvremenom svjetskom hotelijerstvu.

1.19.2 Hotelske mrežne stranice

S obzirom na to da na internetu postoji niz različitih pristupa pa je precizna kategorizacija nemoguća, generalno se sve hotelske mrežne stranice mogu svrstati u četiri osnovne skupine (Ružić i sur., 2009:330):

1) stranice matičnih ili korporacijskih identiteta (proširene verzije brošura o potencijalima tvrtke, uglavnom namijenjene trećim osobama – zaposlenicima i ulagačima; promiču tržišnu poziciju tvrtke, njezinu filozofiju, veličinu, povijest i ostale osobine)
2) mrežne stranice lanaca, koncesija i članstva (kao oblici strukture upravljanja zajednička im je osobina stvaranje trgovačkog imena, marke ili brenda)
3) mrežne stranice pojedinačnih lokacija i objekata (obično donose više pojedinosti o smještaju, uslugama i zabavi)
4) portali i pvortali (nude širok spektar informacija usredotočenih na užu

Online tehnologija, posebice upotrebom mogućnosti koje pruža WEB 2.0, omogućuje brojne marketinške mogućnosti, pa se u literaturi nailazi na čitav niz termina koji pobliže opisuju određenu tehniku e-marketinga u hotelijerstvu.

Prepoznatljiv su trend, općenito na internetu, ali i mrežnim stranicama hotelijera, korisnički definirani sadržaji – generirani sadržaji potrošača ili korisnički definirani sadržaji (*Consumer Generated Media* – CGM*; User Generated Content* – UGC), koji se nastavljaju razvijati i postaju sve važniji i popularniji. To su također diskusijske grupe i forumi, blogovi i društvene mreže kao što su MySpace i LinkedIn, društvene mreže Facebook, Twiter i sl. Gosti sve više pregledavaju i uvažavaju mrežna mjesta kao što su TripAdvisor i specifične hotelske blogove poput HotelChatter.com. Ove aktivnosti kod potencijalnih turista postaju dominantna aktivnost na internetu i danas su postali sastavni dio procesa planiranja putovanja. Kredibilitet informacija na mrežnom mjestu više nije automatski prihvaćen.

U praksi postoji realan sukob stavova između „službenih“ sadržaja (vlastite mrežne stranice hotela, brošure, opisi, tradicionalna kategorizacija itd.) i CGM (*Consumer Generated Media*) sadržaja.

Gost više ne mora prihvatiti idealistički opis hotelijera na njihovoj mrežnoj stranici, već imaju mogućnost o usluzi i sadržajima saznati na temelju mišljenja i komentara bivših gostiju na, primjerice, TripAdvisoru. Internet, a posebno CGM, uveli su novu dimenziju percepcije vrijednosti pojedine kategorizacije. Tako će iskusni potrošači kao vjerodostojnije prihvatiti opis na putničkoj stranici, a manje vjerovati podatcima sa službene stranice hotela.

Nadalje, u suvremenim uvjetima eCRM mora biti vitalna komponenta hotelske internetske marketinške strategije. Sve je važnije razumjeti potrebe klijenata i njihov stil života te graditi marketinšku strategiju na temelju tih potreba. Uspostavljanje obostrano korisnih interaktivnih odnosa s kupcima krajnji je cilj bilo koje eCRM inicijative. Izgradnja interaktivnong odnosa s klijentima sastoji se od tri kritične faze: njeguj, širi, sačuvaj.

Za izgradnju učinkovite eCRM strategije u sektoru putovanja i gostoprimstva hotelijeri trebaju prihvatiti nove, sofisticirane alate i poslovnu praksu u sljedećim područjima (Ružić i sur., 2009:332): povećanje znanja o svojim klijentima, poboljšanje usluga korisnicima za *online* istraživanja/planiranja/rezervacije, personalizacija marketinga i usluga dostave, razviti nove i učinkovitije marketinške tehnike i izgrađivati lojalnost kupaca.

Jedan od jednostavnijih načina održavanja komunikacije s korisnicima jest obavještavanje o novim sadržajima s određenih stranica (RSS *feed*). Ukratko, radi se o tehnologiji nazvanoj RSS (*Really Simple Syndication*), koja omogućava da se pomoću posebnih programa ili dodataka čitaju naslovi i sažeci vijesti, blogovi i sl. Sve korišteniji na hotelskim mrežnim stranicama su i *podcast* datoteke.

Podcast je digitalna datoteka koja sadržava audio ili audio-videozapis koji se distribuira putem interneta koristeći RSS tehnologiju, a namijenjen je gledanju (ili slušanju) na računalu, digitanom prijenosnom uređaju poput iPoda ili televizije, koristeći uređaje poput Apple TV-a.

Naziv *podcast* je složenica rijeci POD *(Personal on Demand)* i engleske rijeci *broadcast.* Iako su na početku *podcasti* bili isključivo audio datoteke, najčešćće u mp3 formatu, danas se za *podcast* uglavnom smatraju video sadržaji. Video *podcast* se još naziva i *vidcast,* a osobe koje se bave *podcastingom* se nazivaju *podcasterima.* RSS agregatori specijalizirani za skidanje *podcasta* zovu se *podcatcheri.*

1.19.3 Mrežne stranice za mobilne uređaje

Sljedeći prepoznatljiv trend (i potreba) u hotelijerstvu kreiranje je mrežnih stranica hotela prilagođenih mobilnim uređajima. Preko 25% korisnika mobilnih telefona i PDA uređaja koriste pristup internetu putem svojih bežičnih uređaja. Većina tih novih uređaja pružaju širokopojasni pristup internetu. Zrakoplovne tvrtke koriste ovu tehnologiju za pružanje obavijesti o promjenama reda letenja. Mogućnosti mapiranja, tražilice i oglašavanja preko mobilnih uređaja samo su neki od područja rasta. Hotelijeri trebaju pratiti ovaj trend i pružati mogućnosti rezerviranja preko mobilnih uređaja.

U cilju privlačenja klijenata putem mobilnih uređaja hotelijeri trebaju:

- napraviti kompatibilnu mrežnu stranicu koju je moguće lako i brzo preuzeti s mobilnog uređaja
- provjeriti je li stranica spremna za mobilne uređaje na http://mr.dev.mobi,
- upisati svoju mrežnu stranicu u tražilice, imenike i lokalne direktorije za mobilne uređaje.

Nakon što su pokrivene osnove, moguće ih je pokrenuti s PPC-om Google za mobilne telefone. Navedeni trendovi i njihova implementacija će s vremenom rasti, usporedno s povećanjem potrošača koji participiraju u mrežnim aktivnostima te povećanjem njihove informacijske i multimedijalne pismenosti. S druge strane tržišni položaj hotelijerstva znatno će biti unaprijeđen korištenjem suvremenih e-marketing strategija.

1.19.4 Izravni marketing

Jedna je od upotreba baze podataka i razvijanje popisa kontakata za izravni marketing. Izravni marketing izvorno je označavao oblik marketinga u kojem su se proizvodi ili usluge kretali od proizvođača do potrošača, bez posredničkog distribucijskog kanala. Izravni je marketing važno sredstvo u CRM programima, tj. programima upravljanja odnosima s klijentima. CRM je naziv koji se obično odnosi na programe vjernosti ili programe marketinga odnosa koji se koriste tehnologijom.

Danas zrakoplovne tvrtke, hoteli, putnički agenti, restorani i *rent-a-car* tvrtke djeluju na tržištima gdje je jaka konkurencija. Najbolji je način povećanja tržišnog udjela krađa od konkurenata. Izravni marketing omogućava tvrtkama razvijanje jakih odnosa s njihovim

klijentima te klijenti ne odlaze kod konkurenata. Programi koji mjere učestalost odsjedanja u hotelu nude članovima posebne cijene, bolju uslugu ovisno o raspoloživosti, posebne užitke, čitave katove te često vlastiti *lounge* s dodatnim pićem.

Zrakoplovne tvrtke razvijaju posebne ponude za svoje redovite putnike. Generalni direktor hotela često poziva stalne goste na večernje koktele. Menadžeri su svjesni da trošenje novca na razvijanje vjernosti među postojećim klijentima može biti učinkovitije nego trošenje novca na pokušaje pridobivanja novih klijenata. Istraživanja pokazuju da je pridobivanje novoga klijenta četiri do sedam puta skuplje nego zadržavanje postojećega klijenta.

1.20 CRM u hotelskoj industriji

Hotelska industrija, kada je u pitanju kreiranje podatkovne baze, u velikoj je prednosti jer ima jednostavan pristup podatcima s obzirom na to da se gosti moraju registrirati, odnosno da prilikom prijave izjave svoje ime i adresu te zavisno od lokacije i ostale detalje, pa čak i privatne podatke. Pored toga, gosti su skloni podijeliti svoje osobne sklonosti s hotelskim osobljem u formalnim i neformalnim razgovorima. Hotel može koristiti tako prikupljene podatke te u sprezi s IT-jem i pružiti gostima dodatne sadržaje. Primjerice, gost koji je izrazio igranje tenisa kao najbolji oblik rekreacije, dobit će na svoj mobitel termine raspoloživosti teniskog terena. Ako gost prihvati takvu ponudu, slijedeći puta dobiva pogodnosti u obliku biranja termina, terena uz gratis opremu i sl. Time se uspostavlja bliska veza s gostima i u potpunosti se zadovoljavaju njihove potrebe. Kako bi se mogli natjecati na visoko konkurentnom tržištu, hotel mora zadovoljiti sve potrebe i očekivanja gosta.

Da bi se to moglo ostvariti, za hotelski je menadžment važno da razumiju osnovne aspekte poslovne uspješnosti koji uvjeravaju kako zadovoljni gosti postaju stalni i lojalni gosti. Stoga u cilju održavanja profitabilnosti poslovanja dostizanju punog zadovoljstva gostiju, a time i pridobivanja njihove lojalnosti, organizacije (hoteli) trebaju se usredotočiti na provedbu modela upravljanja odnosima s kupcima (CRM), strategije koja ima za cilj tražiti, prikupiti i pohraniti prave informacije, potvrditi ih i koristiti (Banga, Kumar, & Goyal, 2013, str. 71).

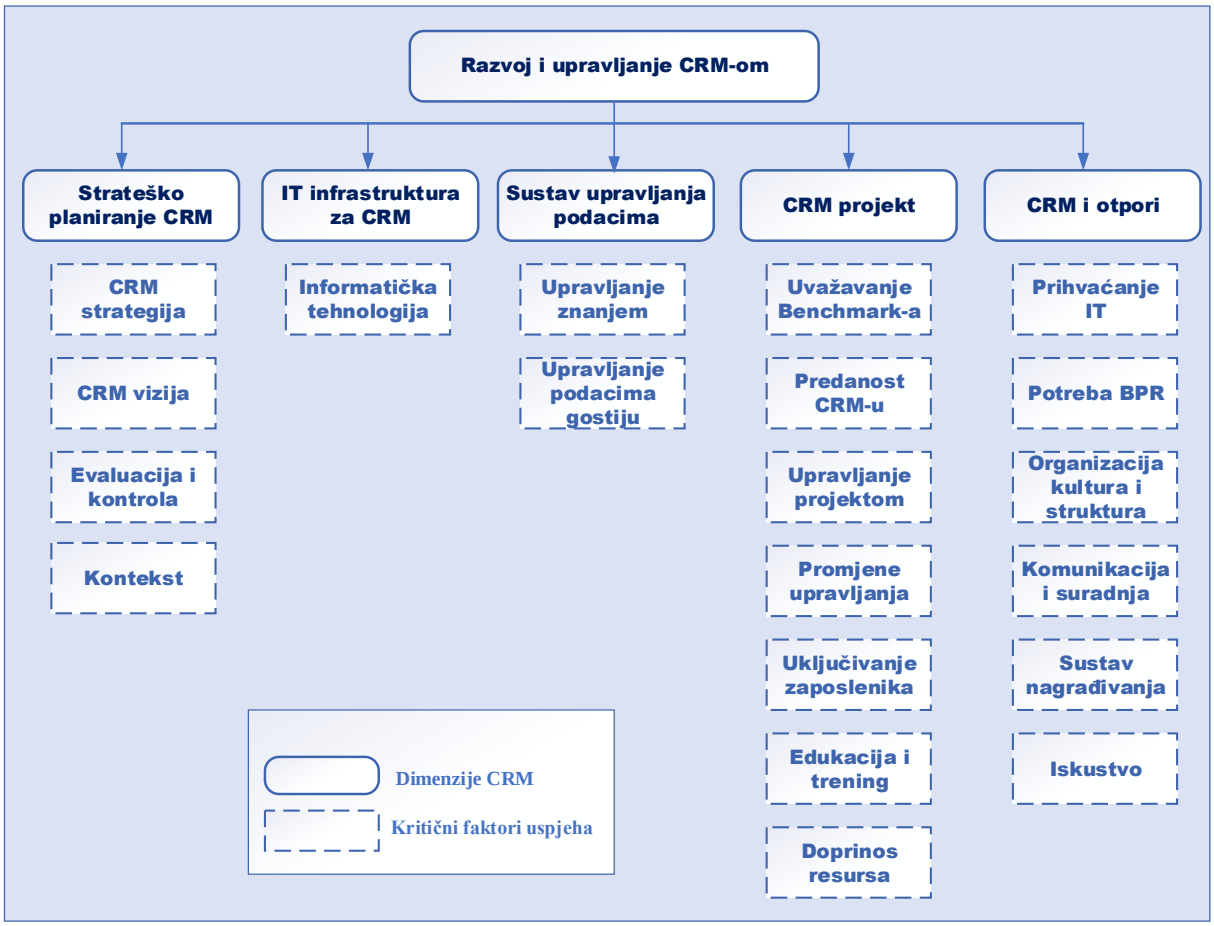
Pojašnjavajući modalitete uspješnosti na hotelskom tržištu Dominici i Guzzo (2010, str. 5) smatraju kako se nije dovoljno samo usredotočiti na privlačenje novih gostiju, već je potrebno veću pažnju posvećivati postojećim gostima primjenom politike „zadovoljstva i lojalnosti“.

Svjetska ekonomija, kako navode Appiah i Kingsley (2010, str. 39), „postaje sve više globalizirana, konkurencija se pojačala i razlike u proizvodima su izblijedjele“. Posljedično, turistička poduzeća sve se više usmjeravaju na upravljanje odnosima s kupcima (CRM), koji postaju središnja orijentacijska točka sposobnosti postizanja liderstva na tržištu i profita.

Parvatiyar i Sheth (2001, str. 3) u svojim konceptualnim okvirima navode dva najvažnija procesa CRM-a, a to su proaktivno uključivanje gosta i izgradnja partnerskih odnosa s najvažnijim gostima.

Razvoj i upravljanje CRM-om prema Zerbino, Aloini, Dulmin, i Mininno (2018, str. 9), moguće je predočiti narednim prikazom.

Slika 26. Razvoj i upravljanje CRM-om



Izvor: prema Zerbino, Aloini, Dulmin, i Mininno, *Big Data-enabled Customer Relationship Management: A holistic approach*, 2018, str. 9.

Iz predočene slike razvidno je pet inputa čija je formulacija izvedena iz kritičke analize odnosa između svakog pojedinog kritičnog čimbenika uspjeha (engl. *Critical Success Factors* – CSF) i baze velikih podataka (*Big Data*).

1.20.1 Proces upravljanja odnosima s gostima

Proces upravljanja odnosima s gostima inicijalno je zamišljen kao marketinški model, koji se tijekom vremena razvijao sukladno evoluciji marketinške teorije i prakse. U tom razvojnom procesu prolazio je kroz različite faze koje su u pravilu ovisile o razvoju informacijsko-komunikacijske tehnologije. U početnim fazama CRM su činili recepcionari vlastitom memorijom, a potom se prešlo na zapise i kartoteke, a pojavom računala na datoteke i opsežne baze podataka.

Upravljanje odnosima s gostima ciklički je proces u kojem se prikupljeni podatci o gostima transformiraju u odnos s gostom na način da se ti podatci koriste kako bi gostu ponudili ono što on očekuje. Time započinje proces upravljanja odnosima, koji će hotelu omogućiti stvaranje dugoročnih, upravljivih i profitabilnih odnosa s gostima.

Upravljanje odnosima s gostima čine ponavljajući postupci u kojima se, kako navodi Panian (2002, str. 222), mogu uočiti četiri bitna skupa aktivnosti: „(1) stvaranje, odnosno otkrivanje znanja, (2) planiranje tržišta, (3) interakcija s klijentima te (4) analiza i profiliranje“.

1) ***Stvaranje, odnosno otkrivanje znanja*** aktivnost je koja je usmjerena na analiziranje svih prikupljenih podataka o gostu kako bi se moglo utvrditi kakav je postojeći i procijeniti budući tržišni potencijal te sukladno tome odrediti strategiju ulaganja u CRM. Aktivnosti se provode: a) prepoznavanjem, b) segmentiranjem i c) predviđanjem ponašanja gostiju. Sustavnim bilježenjem svih tako prikupljenih podataka, stavova i mišljenja te njihovim zapisom u elektroničkom obliku stvara se baza podataka, koja integriranjem više hotela u lancu rezultira velikom bazom (*Big Data*). Tako prikupljeni podatci pogodni su za analizu povijesnih informacija, ali i kao sredstvo marketinških aktivnosti. Nadalje, obrada takvih podataka kroz sustav za podršku odlučivanju (DSS) pomaže menadžmentu pri donošenju boljih strateških, taktičkih i operativnih odluka. Informatički podržan CRM prikuplja detaljne podatke iz brojnih interakcija s gostima. Izvori koji služe za obradu podataka se nalaze u samom hotelu putem elektroničke kartice gosta kojom se on kreće po hotelu i koristi određene usluge, eventualne žalbe i prigovore, financijske transakcije kod plaćanja

rezervacije ili računa. Drugi su vanjski izvori dobiveni od mobilnih aplikacija, korespondencije e-poštom, reakcije na kataloge i marketinške poruke i sl. Pored navedenog, sustav prati službene statističke i analitičke izvještaje koje publiciraju vladine i nevladine institucije, organizacije i agencije.

2) ***Planiranje tržišta*** podrazumijeva izradu planova za cijeli splet marketinških aktivnosti, kao i planiranje najpovoljnijih komunikacijskih kanala isporuke. Planiranje tržišta temelji se na poznavanju situacije u bližem, širem i globalnom okruženju. Naime, hotelsko tržište kao segment turističkog tržišta ima svoje pravilnosti i trendove, ali isto tako mora zbog nepredvidljivosti imati u pričuvi i dodatne planove. Svi planovi moraju se temeljiti i aktivirati isključivo na osnovi prikupljenog znanja.
3) ***Interakcija s klijentima*** ključna je aktivnost s postojećim gostima, bivšim i potencijalnim gostima, koja se provodi na temelju relevantnih i ažuriranih podataka. Koji i koliko će se, kao i kada će se upotrijebiti interakcijski kanali zavisit će o planovima tržišta. Informatička podrška tu ima odlučujuću ulogu. Sustavi za podršku odlučivanju mogu upravljati ponudom uz korištenje više interakcijskih kanala i aplikacija, kao što su aplikacije za korespondenciju s gostima, prodajne aplikacije, aplikacije za realiziranje kontakata s gostima i interaktivne aplikacije. Navedene aktivnosti se nadovezuju stvaranju i otkrivanju znanja i planiranju tržišta.
4) ***Analiza i profiliranje*** čini splet aktivnosti koje podrazumijevaju kontinuirano učenje na temelju interakcije s gostima, pri čemu se prikupljaju i analiziraju podatci do kojih se dolazi tijekom dijaloga s gostom. Takve analize rezultirat će, kako navodi Panian *(Izazovi elektroničkog poslovanja*, 2002, str. 224) „boljim profiliranjem poruka, komunikacija, cijena, količina, lokacija, pristupa i vremenskog usklađivanja poslovnih aktivnosti te osmišljavanje djelotvornijih načina marketinške i prodajne stimulacije klijenata“.

U kontekstu hotelskih poduzeća, cilj bi trebao biti održavanje odnosa – kontakta sa kupcem, prije, za vrijeme i poslije posjete, putem mrežne stranice, e-pošte, pozivnih centara, info-kioska, turističkih informativnih ureda i slično. CRM ima više mogućnosti primjene u turizmu nego u drugim gospodarskim sektorima, a to su: (1) povećanje učinkovitosti marketinga, (2) korisnički servisi i (3) razvoj novih proizvoda. Naročito je veza između CRM-a i razvoja novih proizvoda, zato što turističke tvrtke imaju puno bliži odnos sa svojim klijentima nego većina poduzeća u drugim sektorima, a posebice tvrtke iz proizvodnje. Zapravo, turističko je tržište danas tržište kupaca, a ne više tržište prodavatelja kakvo je nekad bilo.

Zaključno, glavni je zadatak svih opisanih aktivnosti privlačenje novih gostiju, njihov ponovni dolazak, povećanje profita i najvažnije, povećanje zadovoljstva svakog gosta.

1.20.2 Baze podataka osnova uspostave e-CRM-a

Kako bi se uspostavio učinkovit model CRM-a, u turističkim je poduzećima potrebno kreirati podatkovnu bazu o korisnicima turističkih usluga. Podatkovna je baza „zbirka podataka o postojećim, potencijalnim ili sumnjivim korisnicima, koja se kreira u marketinške svrhe i koristi prilikom prodaje usluga i održavanja odnosa sa korisnicima“ (Kotler, Bowen, & Markens, Marketing u ugostiteljstvu, hotelijerstvu i turizmu, 2010, str. 702).

Ne tako davno sve to je bilo u glavama šefa recepcije, šefa sale ili kuhinje, o čijim je sposobnostima ovisilo upravljanje odnosima s klijentima, da bi suvremene baze podataka kod „snalažljivijih“ kreatora bile formirane kao velike baze podataka (engl. *Big Data*) povezane s bazama podataka pratećih turističkih agencija, ugostiteljskih objekata, prijevoznika…

Podatkovna baza stvara se kroz duže vremensko razdoblje (5 – 10 godina), odnosno od trenutka kada je neki hotel, ugostiteljski ili turistički subjekt počeo koristiti računalo u svrhu rezervacija, transakcija i u računovodstvene svrhe. Sustavno se prikupljaju podatci o količini obavljenih transakcija svakog gosta i svim podatcima vezanim uz nju (kada, gdje, koliko, svrha, namjena) (Ryals & Payne, 2001, str. 17). Naknadno se podatci o korisnicima ekstrapoliraju u zasebne baze podataka, koje se pak strukturiraju prema profilu korisnika, čime postaju sastavni dio modela CRM-a.

Takvim načinom stvarane su značajne podatkovne baze, koje su se mogle pretraživati po karakteristikama i atributima iz profila korisnika. Aplikacije su koristile pojedine baze podataka i automatski odašiljale promidžbene poruke korisniku inkorporirane u rođendansku čestitku ili neki događaj zabilježen u njegovu profilu. Takav pristup postajao je sve agresivniji i graničio s „gerila marketingom“ sve do 2016. godine i donošenja Uredbe EU-a 2016/679, kojom se ograničava uporaba osobnih podataka u marketinške (i sve druge) svrhe bez privole.

Naravno, sukladno s Uredbom EU-a 2016/679 i Zakona o provedbi Opće uredbe o zaštiti podataka (NN, 2018/42), korisnici moraju dati privolu da se njihovi podatci koriste u marketinške svrhe.

Marketing koji se temelji na podatkovnim bazama (engl. *Database Marketing* – DM) strukturiranim prema postojećim i potencijalnim kupcima, ali i konkurencije, procesuira navike korisnika od općih (preferencije objekata, izleta, događanja, manifestacija) do posebnih (proslave rođendana, odabir hrane i pića, zabave), kreirajući ponudu koju upućuje korisniku u vidu dobronamjerne preporuke.

1.20.3 Big Data

Velike baze podataka (engl. *Big Data*) u pravilu nastaju dvama načinima. Prvi je mukotrpno prikupljanje podataka iz hotelskih računala o gostima koji su boravili u hotelima otkada se podatci s recepcije vode elektroničkim putem. Uglavnom se tu radi o nesistematiziranim podatcima iz kojih se uz hotelima dostupne softverske alate teško mogu ekstrapolirati karakteristike lojalnost gostiju. Ono što je moguće saznati jest broj ponavljanja, odnosno učestalost dolazaka istih gostiju, vrijeme dolazaka, potrošnju i način plaćanja.

Drugi način je da se upravljanje odnosa s gostima prepusti za to specijaliziranim marketinškim agencijama, koje posjeduju vlastite baze podataka i raspolažu sofisticiranim alatima koji pomoću zadanih algoritama segmentiraju goste potrošače. Nadalje, oni mogu „pročistiti velike datoteke“ od dvostrukih podataka (engl. *Duplicate Files*), proširivati podatke (engl. *Bootstraping*) te učinkovito profilirati goste.

Big Data tehnologije pružaju velike mogućnosti za statističke zaključke o masovnim analizama, ali one također donose nove izazove koje treba riješiti, posebno u usporedbi s analizom pažljivo prikupljenih manjih skupova podataka. Deskriptivna statistika je osnovna metoda *Big Data* analitike, koja uključuje sažetak i opis jednostavnih statističkih testova, kao što su srednje vrijednosti, medijani, standardna devijacija, varijanca i proporcije.

Međutim, kada je *Big Data* analitika u funkciji CRM-a, tada je potrebno identificirati relevantne varijabilne skupine, analizirati njihovo praktično značenje pomoću testova proporcije između stalnih gostiju i onih koji su zabilježeni samo jednom (Talón-Ballestero, González-Serrano, Muñoz-Romero, & Rojo-Alvarez, 2018, str. 188). Korištenjem *Bootstrap* tehnike moguće je dobiti točne rezultate i na manjim, ali kvalitetnim uzorcima.

Primjena analitike *Big Data* u hotelskoj je industriji uvelike promijenila upravljanje odnosa s gostima, donošenja poslovnih odluka i pojednostavila obradu velike količine podataka. Iako je iskustvena menadžerska analiza nezaobilazna, *Big Data* tehnologija prezentira u realnom vremenu čak pet analitičkih pristupa: deskriptivnu analitiku, istraživačku analitiku, prediktivnu

analitiku, preskriptivnu analitiku i preventivnu analitiku, što čini koristan alat za kontrolu menadžerskih odluka. Naime, većina analiza *Big Data* opisne su i istraživačke prirode, ali čak i jednostavni deskriptivni statistički podatci omogućuju prepoznavanje jednostavnih i jasnih obrazaca, koji postaju izuzetno korisni za odlučivanje.

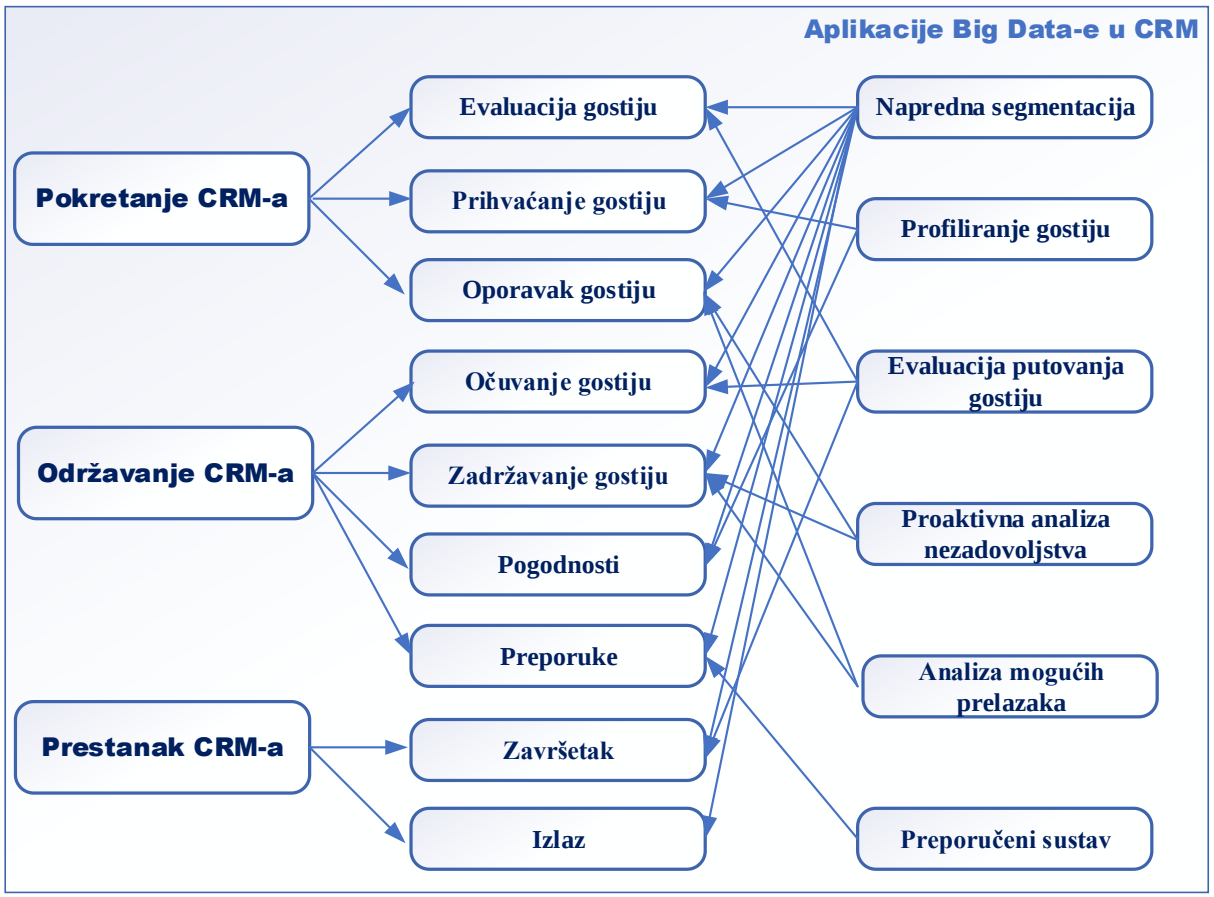
U hotelskoj se industriji *Big Data* tehnologija uglavnom koristi za prodaju proizvoda, analizu ponašanja gostiju na društvenim medijima, kao i izvanmrežno pretraživanje i analizu podataka.

Općenito, velika količina dostupnih podataka o gostima otvara relevantne mogućnosti za hotelska poduzeća, koje mogu rezultirati snažnom prednošću nad konkurencijom. Daljnji tehnički i napredniji alati omogućit će bolje iskorištavanje dostupnih informacija o gostima i njihovo ponašanje u destinaciji.

1.20.4 Veza između tehnologije „Big Data“ i CRM-a

CRM proces ima tri osnovne dimenzije – pokretanje odnosa, održavanje odnosa s gostima i prestanak odnosa – podijeljene u ukupno devet poddimenzija, kako je to predočeno narednom slikom. BD omogućava razvoj napredne segmentacije gostiju u realnom vremenu. Potencijalni učinak tehnologije *Big Data* na CRM predočava se narednom slikom.

Slika 27. Potencijalni učinak tehnologije *Big Data* na CRM



Izvor: Zerbino, P., et al. *Big Data-enabled Customer Relationship Management: A holistic approach*, 2018, str. 822.

Velika konkurencija na turističkom tržištu, kao i novi trendovi u turizmu koji korisnicima formiraju itinerar s većim brojem destinacija u vremenu odmora, uzrokuje i prelaske gostiju iz jednog u drugo hotelsko poduzeće. Prelazak gostiju za hotel znači gubitak prihoda i stoga je hotelima jako bitno znati kako utjecati na moguće osipanje stalnih gostiju. Prediktivna analiza može s određenom vjerojatnošću prema poznatom uzorku i odgovarajućem algoritmu prepoznati na koje goste u nekom budućem vremenu ne treba računati.

Ako hotelsko poduzeće uspije predvidjeti koji segment gosta ima namjeru prelaska (engl. *Churn*) kod konkurencije, tada ga se može pokušati zadržati marketinškim aktivnostima (raznim pogodnostima ili poklonima).

Problematika „*Churn* gosta“ naročito do izražaja dolazi kada se širi preko društvenih medija.

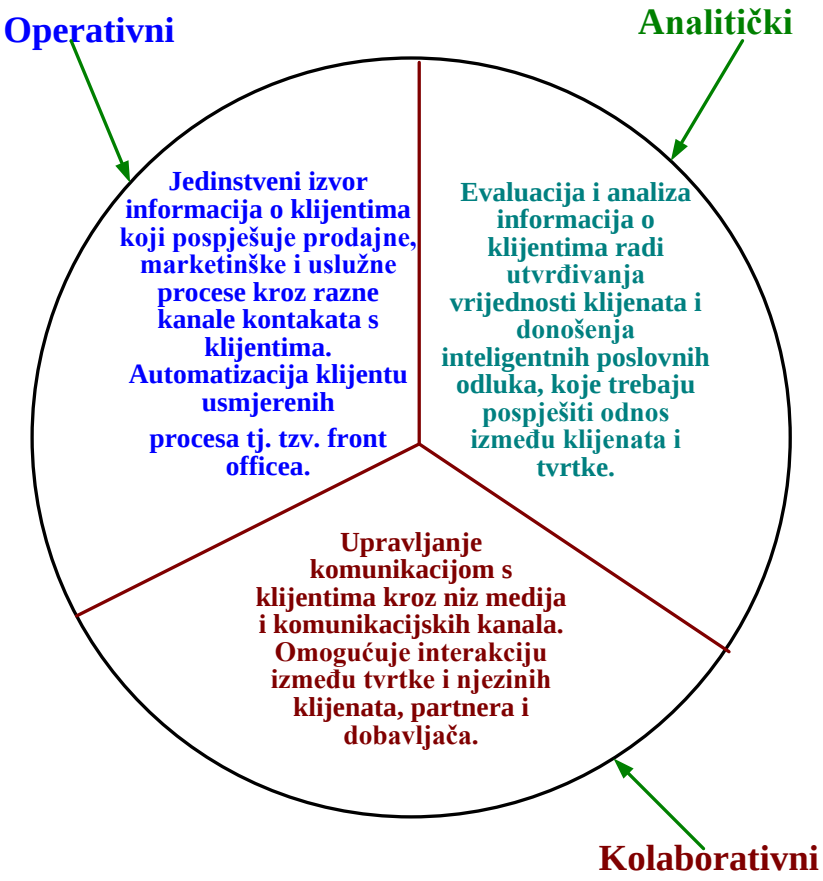
1.20.5 Komponente CRM-a

CRM se prvenstveno odnosi za bolje upravljanje poznavanjem gostiju i njihovu razumijevanju u funkciji pružanja što kvalitetnije usluge. CRM je model koji gosta stavlja u središte organizacije. Gost (turist) je važna komponenta CRM-a, međutim CRM se isto tako bavi koordiniranjem odnosa s gostima kroz sve poslovne funkcije, točke interakcije i okruženje. CRM donosi brojne koristi za hotele, kao što su zadovoljstvo i odanost gostiju, povećanje prihoda, smanjenje troškova i održivu konkurentsku prednost. CRM uključuje integraciju tehnologije i poslovnih procesa koji se koriste u svrhu zadovoljavanja potrebe gosta. Sa stajališta IT-ja, CRM se definira kao integrirana tehnologija u funkciji nekog hotelskog poduzeća koja se ogleda kao skladište podataka, mrežne stranice, intranet/ekstranet, telefonske podrške sustava, računovodstvo, prodaja, marketing i proizvodnja. Drugim riječima, CRM je pojam koji se odnosi na to kako hotelsko poduzeće može zadržati svoje najvažnije kupce i u isto vrijeme smanjiti troškove, povećavajući vrijednosti interakcije te kao rezultat maksimizirati dobit. CRM se također može definirati kao „sveobuhvatni pristup, koji diskretno integrira prodaju, službu za korisnike, marketing, podršku na terenu i ostale funkcije koje se odnose na kupce“ (Xu, Yen, Lin, & Chot , 2002, str. 444).

Prava vrijednost za hotelsko poduzeće nalazi se u vrijednosti koju stvaraju za svoje goste i u vrijednosti koju gosti vraćaju u poduzeće. Vrijednost se nalazi u znanju gosta i kako poduzeće koristi to znanje za upravljanje odnosima s gostima.

Komponente koje čine CRM su: 1) strateška, 2) operativna, 3) analitička, 4) komunikacijska i 5) kolaborativna.

Slika 28. Komponente CRM-a



Izvor: Reynolds, J.: *A Practical Guide to CRM*, CMP Books, New York, 2002., str. 7

Analitička komponenta CRM-a procesuira podatke dobivene od operativnog CRM-a. Dobivene informacije sustavno se obrađuju, pripremaju i analiziraju. Iz rezultata analize mogu se izvesti preporuke za djelovanje prema gostima i segmentima gostiju. Druga mogućnost analitičkog CRM-a je usredotočiti se na buduće ponašanje gostiju, kako bi se predvidio budući potencijal i procijenili zahtjevi gostiju. Podatci dobiveni iz operativnog CRM-a mogu se koristiti od jednostavnih metoda analize (poput ABC analize), ali i posebno s opsežnim analizama koje goste prepoznaju sofisticiranim metodama poslovne inteligencije (BI metode). CRM alati imaju automatizirane postupke ocjenjivanja integriteta gostiju.

Komunikacijski CRM komponenta je koja omogućuje izravnu i neizravnu komunikaciju između gosta i hotela. Omogućuje hotelskom poduzeću prenijeti ponude i informacije gostima. Izravnom komunikacijom hotel traži izravan kontakt s gostom. To uključuje telefonske pozive, neposredne kontakte i razgovore gosta i djelatnika hotela. Neizravna (neosobna) komunikacija ima različite mogućnosti kontakta: putem pisma, e-pošte, SMS-a, poruke ili društvenih medija.

Kolaborativni CRM komponenta je koja podržava suradnju internih i eksternih izvora podataka. Interno je dizajniran za pružanje transparentnosti i dostupnosti podataka o gostima, koordinira zadatke različitih odjela i funkcija zaposlenika koji doprinose zadovoljstvu gostiju hotela. Vanjski izvori podataka su informacije o partnerima, agencijama, prijevoznicima, dobavljačima, serviserima, lokalnoj upravi, udrugama i sl. Ova komponenta može optimizirati segmente duž cijelog lanca vrijednosti.

Znanje je osnovica CRM-a, ali, kako pokazuju dosadašnja istraživanja, kod nas i u svijetu još uvijek je mali broj turističkih poduzeća koje prenose informacije gostu proširujući njegove spoznaje, čime propuštaju priliku povećati vrijednost svojih gostiju. Međutim primijenjen na pravi način, CRM je alat koji doprinosi profitu. Ako hotelsko poduzeće pravilno procesuira prikupljene korisničke podatke te ih prenese u znanje, a zatim to znanje iskoristi za izgradnju odnosa s gostima, stvorit će lojalnost, nakon čega slijedi ostvarenje dobiti.

Ovo je vrlo važno jer, kako navodi Mc Kim (2002, str. 375), „ključ uspjeha u svakom poslu je usredotočiti se na stjecanje kupaca koji stvaraju profit i kad ih jednom pronađete, nikada ih ne napuštajte“.

1.20.6 Alati CRM-a

Upravljanje odnosima s kupcima obično podržava softver ili podržavajući računalni programi. Bez digitalnog i automatiziranog softvera, CRM bi bio praktično neupotrebljiv zbog velikog broja podataka o gostima, što bi iziskivao i veći broj djelatnika odnosno previše „ručnog rada“, što je u suvremenim uvjetima neprovedivo. Čak ako se koriste podržavajući programi poput MS Excela (tablični kalkulator), kojim se može procesuirati velika količina podataka, potreban je stručni programski analitičar koji bi mogao posluživati CRM tek u nekom malom hotelu. Stoga su prikladnija gotova softverska rješenja koja pohranjuju i generiraju podatke o gostima te su promptno raspoloživa. Softver temeljem formirane baze podataka prati sve prodajne aktivnosti i komunikacije s gostima.

CRM alati nisu izolirani alat za brigu o kupcima. Zajedno s drugim programima oni podržavaju kompletni odnos s gostima. Naime CRM softver ne procesuira samo standardne podatke o kupcu, već bilježi sve razgovore, pozive, žalbe i druge zahtjeve te gosta može i učiniti izravno dostupnim. Pored toga, pomoću CRM alata moguće je izraditi profil svakog gosta. CRM softver

mora korisnicima pružiti brze i jednostavne procjene u realnom vremenu. Nadalje, on mora razlikovati goste prema individualnim potrebama i prohtjevima i odabrati kanal za komunikaciju koji najviše odgovara korisniku (pisma, e-pošta, Messenger, Viber i telefonske pozive…).

CRM alati softverski su programi koji predstavljaju intelektualno vlasništvo njihova autora i kompanije koja ih proizvodi i distribuira. Na tržištu se nalazi veći broj takvih alata, a njihova cijena varira o broju modula, odnosno mogućnosti koje pruža. Moguće je kupiti gotov program, prilagodljiv program te ih iznajmljivati na zahtjev. Pri odabiru CRM-a hotelsko poduzeće mora uzeti u obzir slijedeće kriterije (Engelen & Zafer, 2019, str. 7):

- koliko dugo i u kojem smjeru (koliko modula) se predviđa korištenje CRM-a te na temelju potreba izračunati ukupni trošak
- koja je početna cijena alata?
- koliko koštaju dodatni moduli?
- koliko vremena je potrebno za implementaciju?

Pri kupovini softvera valja uzeti u obzir da još obično postoje troškovi održavanja, ažuriranja ili podrške. Ako se hotelsko poduzeće odluči za korištenje „na zahtjev“ preko interneta putem oblaka, moguć je pristup softveru u bilo kojem trenutku i s udaljenih mjesta, a plaćanje se vrši po vremenu korištenja.

Na europskom tržištu CRM softvera 2019. godine bili su prisutni sljedeći komercijalni nazivi: Aurea, Centralstation CRM, Freshworks, Hubspot, Microsoft Dynamics CRM, Pipedrive, Salesforce, Teamleader, TecArt i Zoho.

Kriteriji koje bi trebao zadovoljiti učinkoviti softver za hotelsko poduzeće su (Engelen & Zafer, 2019, str. 8): upravljanje kontaktnim podatcima, uvoz i izvoz podataka o gostima, upravljanje podatcima, upravljanje kampanjom, upravljanje prilikama, adaptabilnost CRM-a bez dodatnog programiranja, mogućnost korištenja „pametnih telefona“, analitički alati, analiza važnosti gosta, elektronički marketing, integracija društvenih mreža, upravljanje ponudama i zadatcima, funkcija pozivnog centra, *online chat* funkcije, samoposlužujući (engl. *self-service*) portal, kao i podrška bazama podataka. Softveri koji zadovoljavaju navedene kriterije pogodni su za korištenje u hotelskoj industriji.

Implementacija CRM sustava prilično je zahtjevna po pitanju zadovoljavanja željenih kriterija i pritom se treba koristiti iskustvima i recenzijama postojećih korisnika iz hotelske industrije.

Nadalje, može se očekivati otpor pri prelasku iz jednog uspostavljenog sustava u drugi, što je često organizacijski i emocionalno složen proces.

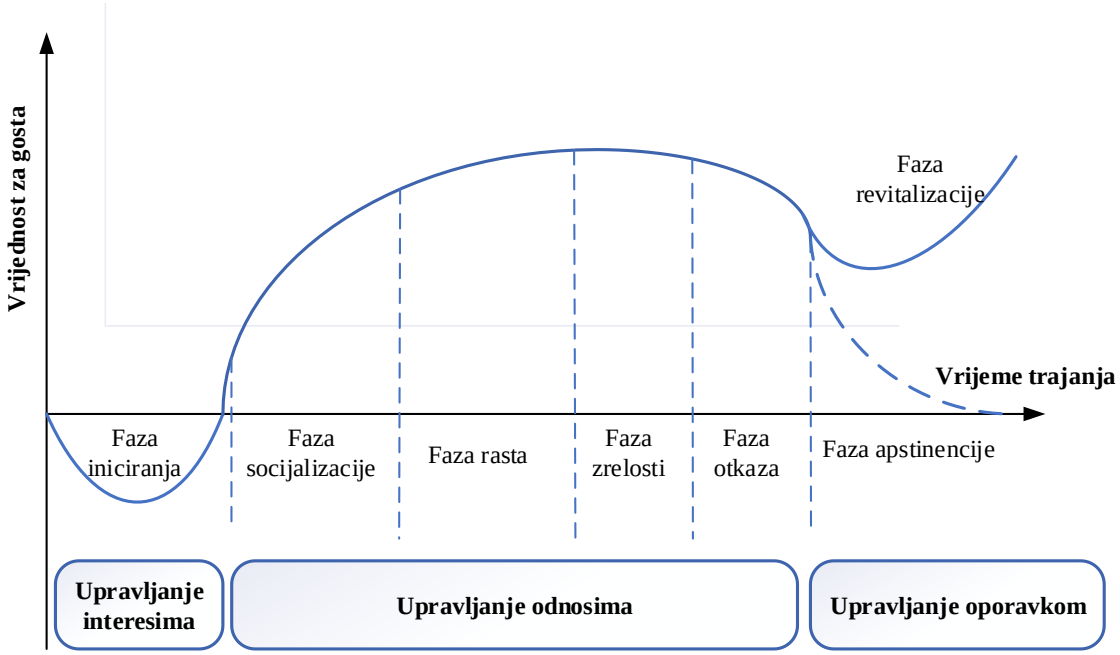
1.20.7 Životni ciklus CRM-a

Svaki proizvod ili usluga ima svoj životni ciklus pa se tako i CRM može usporediti sa životnim ciklusom proizvoda. Razlika između njih je da se životni ciklus proizvoda/usluge tiče proizvoda/usluge, a životni ciklus odnosa s kupcem govori o odnosu kupca prema poduzeću koji je proizvođač proizvoda/usluge. Životni ciklus odnosa s kupcem sastoji se od naredne tri glavne faze.

- ***Upravljanje interesom*** podrazumijeva pokretanje novih odnosa s korisnicima. Potencijalne goste aktivno se potiče na korištenje idejama i razmjenom interesa. To uključuje korištenje različitih oblika komunikacijskih kanala (od marketinga na mrežnim stranicama do telefonskih poziva).
- ***Upravljanje odnosom*** faza je zadržavanja korisnika, koja se sastoji od više segmenata od kojih svaki predstavlja rizik gubitka potencijalnog stalnog gosta. U fazi socijalizacije hotelsko poduzeće predstavlja svoj program vjernosti i naglašava njegove prednosti s kojima upoznaje gosta. Kada gost prihvati program, faza socijalizacije prijelazi u fazu rasta. Zadovoljan gost postaje stalan gost te je stoga ova faza najvažnija jer zadovoljan gost pokreće priču uspjeha usmenom predajom, preporukama prijateljima i članovima obitelji. Faza zrelosti može varirati ovisno o rasponu usluga, a prestat će zasićenjem ili promjenama uvjeta (rezervacija, promjena cijena, vanjski utjecaji i sl.). Faza raskida odvija se na kraju faze lojalnosti kupca. Da se to spriječi, gosti moraju biti trajno zadovoljni.
- ***Upravljanje oporavkom*** potrebno je kada nastupi raskid i tada je potrebno koristiti različite ponude kako bi motivirali gosta za ponovni dolazak, putem popusta ili drugih promocija.

Vizualno se životni ciklus CRM-a predočava narednom slikom.

Slika 29. Životni ciklus CRM-a



Izvor: prema Stauss (2011)

Iz prezentiranog je vidljiva linija kroz koje faze prolazi upravljanje odnosa s gostima, na kojoj se uočava mjesto prekretnice gdje počinje faza revitalizacije, odnosno gdje CRM završava svoj životni ciklus. Kada će se to dogoditi ovisi o progresu razvoja informacijske tehnologije, ali i nepredvidivih okolnosti iz okruženja (primjerice COVID-19).

1.20.8 IT u funkciji primjene e-CRM modela u turizmu

Primjena e-CRM modela podrazumijeva povezivanje poslovnih procesa i funkcija, kao i razvoj odnosa s kupcima, putem direktnih i *online* kanala komuniciranja. Od posebne je važnosti primjena modela e-CRM-a u turizmu s ciljem razvoja profitabilnih i dugoročnih odnosa s *online* kupcima. Model e-CRM u turizmu pruža korisnicima jednostavno i brzo pretraživanje ponuda putem mrežnih lokacija, pružanje dodatnih usluga, popusta itd. Prednosti e-CRM-a u turizmu (Kabiraj & Shanmugan, 2009, str. 8-9) su:

- formiranje baza podataka korisnika turističkih usluga, u cilju jednostavnijeg dobivanja podataka o potencijalnim kupcima putem nižih troškova mrežnih pretraživanja i održavanja kontakata sa postojećim korisnicima
- jednostavniji pristup informacijama o turističkim proizvodima putem mrežnih stranica

- učinkovito i pravovremeno rješavanje problema ili nezadovoljstva korisnika turističkih usluga
- širenje e-WOM-a
- obavljanje umrežene prodaje putem mrežnih stranica (booking.com ili ostala *dot-com* poduzeća u turizmu)
- pružanje mogućnosti pretraživanja, udobnosti i pogodnosti *online* kupovine
- obavljanje segmentacije tržišta i prepoznavanje visoko profitabilnih korisnika
- povećanje razine zadovoljstva *online* korisnika
- povećanja stope ponovne kupovine turističkih usluga i povrat izgubljenih korisnika
- učinkovitiji sustav interne komunikacije, povećanje razine zadovoljstva zaposlenih i dr.

Važnost povećanja udjela korisnika u prodaji *online* usluga u turizmu objašnjava se putem tzv. teorije angažmana (engl. *Theory Angagament*). *Online* korisnici sve više aktivno sudjeluju u pretraživanju turističkih usluga i to putem markiranja ponuda, slanja e-pošte, ostavljanja komentara te putem davanja prijedloga za poboljšanje ponuda (Luck & Lancaster, 2003, str. 222).

Međutim, *online* korisnici nisu lojalni korisnici s obzirom na to da pretraživanjem interneta nailaze na povoljnije načine prijevoza, bolji smještaj, jeftinije dodatne usluge, bonuse i sl. Svoj angažman realiziraju stvaranjem vlastitog paketa (Wynne, Berthon, Pitt, Ewing, & Napoli, 2001, str. 425) i time prestaju biti ovisni o turističkim agencijama.[3]

Prednosti koje od implementiranja e-CRM-a u turističkim djelatnostima ogledaju se u manjim troškovima transakcija i učinkovitijoj interakciji s klijentima. Nedostaci primjene e-CRM-a, koji su do izražaja dolazili u početnom razdoblju implementiranja početkom milenija, sve se manje uočavaju (Thao & Swierczek, 2008, str. 195-196).

Naime, problemi IT infrastrukture praktički su nestali, kadrovi su svladali i saživjeli se s novom tehnologijom. Pravne i financijske prepreke pri transakcijama svedene su na minimum, *cyber* sigurnost je višestruko povećana, a početna skeptičnost klijenata prevladana.

Klijenti su prihvatili e-CRM na način da su dopustili prihvaćati sadržaje odaslane od pošiljaoca (hotela, agencije, prijevoznika…) i samim time dobrovoljno stupili u interakciju. Dobrovoljnost klijenata zavisi o području njihova interesa (odmor ili doživljaj), kalendara (sezona ili izvan sezone), područja, godišnjeg doba i sl. Budući da CRM koristi svoju bazu podataka, on odašilje

[3] Jedan od razloga bankrota Thomasa Cooka.

poruke na temelju kreiranog pojedinačnog profila klijenta u vremenu koje prethodi donošenju klijentove odluke o korištenju turističkih usluga.

Sama činjenica da je klijent pristao primati propagandni materijal i aktivno sudjelovati u anketama ili komentirati nove proizvode, uključila ga je u prostore e-zadovoljstava i e-lojalnosti, čime je e-CRM ispunio svoju primarnu zadaću.

1.20.9 E-zadovoljstvo klijenata u turizmu

Opća definicija zadovoljstva klijenata u turizmu trebala bi pojednostavljeno sadržavati stupnjeve poput: zadovoljan, izuzetno zadovoljan i nezadovoljan. Zadovoljan je onaj „ koji ima ono što želi, kome je želja ispunjena, koji ne traži više od onog što ima“ (Znanje, 2019). Budući da je turizam kompleksan pojam sastavljen od brojnih proizvoda i usluga, a time i proizvođača i davatelja usluga, teško je povjerovati da je imalo zahtjevniji turist na svojem putovanju u boravku u nekoj destinaciji bio baš u cijelosti zadovoljan. Iako turističke djelatnosti teže (i moraju težiti) ka potpunoj izvrsnosti, ona ostaje u domeni „idealne usluge“.

Ono što e-CRM omogućuje jest povećanje razine zadovoljstva *online* korisnika usluga. Bitne odrednice e-zadovoljstva klijenata su: 1) razina povjerenja, 2) kvaliteta *online* usluga, 3) udobnost, 4) *web* dizajn i 5) financijska sigurnost prilikom obavljanja *online* transakcija (Horn , Feinberg, & Salvendy, 2005, str. 108).

Kvalitetu *online* usluga čine pouzdanost i raspoloživost. Jedna od najčešće korištenih metoda interakcije davatelj usluge – klijent jest „čavrljanje“ (engl. *chat*), koje se odvija u realnom vremenu i kojim se služe klijenti vični brzini tipkanja, dok drugi koriste e-poštu, SMS poruke ili razne oblike *messengera*. Klijent pritom zadržava svoju osobnost u interakciji te očekuje empatiju i ljubaznost pri komunikaciji. Fizička neprisutnost mu omogućava slobodnije izražavanje, nema opterećenja brzine odgovora, ima vremena za razmišljanje o pitanju, konzultirati se o odgovoru i sl.

Čavrljanje ne stvara obvezan odnos u pravnom smislu. Klijent može dogovoriti neku uslugu do najsitnijih detalja, ali, ako je ne potvrdi, ona ima samo informativan karakter. Početkom milenija, kako navodi Lang (2000, str. 370), dvije trećine *online* klijenata informira se putem interneta, ali ipak njih oko 56% rezervira svoje putovanje klasičnim načinom u turističkoj agenciji. Samo 20 godina kasnije preko 80% turista svoje rezervacija obavlja *online*.

1.20.10E-odanost

Odanost (lojalnost, privrženost, vjernost) kupaca pojam je čija se definicija širi i evoluira u marketinškoj komunikaciji pa se tako odanost može temeljiti i na vjerovanjima ili naklonjenosti prema nekom proizvodu ili usluzi, može se manifestirati kao emocionalna povezanost s time ili se može promatrati kao jednostavno, redovito korištenje nekog proizvoda ili usluge.

Da bi se ostvarila i zadržala odanost svojeg korisnika, turistička poduzeća nude poticaje, koji će povećati vrijednost za kupce i na taj način stvoriti vjernost među njima. Iz te perspektive, kako navode (Plazibat, Šušak, & Šarić, 2016, str. 307), kupci dugoročno posluju s poduzećem da zadovolje svoje potrebe.

1.20.11CRM i angažman gosta

Izraz angažman (engl. *engagement*) često se upotrebljava naizmjenično, ovisno o polju ili kontekstu gdje se primjenjuje. Tako u psihologiji pojašnjava vezu između psihološkog i bihevioralnog stanja. Marketinški teoretičari Ray, Kim, i Morris *(The central role of engagement in online communities*, 2014, str. 531) objašnjavaju angažman kao „holističko psihološko stanje u kojem se netko nalazi kognitivno i emocionalno potaknuti društvenim ponašanjem".

Društveni mediji i mobilni uređaji promijenili su odnos koji je bio uspostavljen između hotelijera i gostiju. Hotelska poduzeća nastoje na sve načine privući goste pa tako rado prihvaćaju njihov angažman u kreiranju usluge. Štoviše, Gallupovo istraživanje potvrđuje kako visoko angažirani gosti 23% više doprinose u smislu profitabilnosti, prihoda, udjela u portfelju usluga u odnosu na prosjek gostiju u hotelijerstvu (Venkatesan, 2017, str. 291). Isto je istraživanje ukazalo da visok udio menadžera u hotelijerstvu (74%) smatra kako treba preispitati i promijeniti svoj pristup „angažiranim gostima" u narednim godinama što uključuje i dublje razumijevanje provedbe strategije „angažmana gostiju".

Istraživanje angažmana gostiju i dalje ostaje izazov u hotelijerstvu, a ono posebice zahtijeva uključivanje zaposlenika, kao i promjene tradicionalnih marketinških praksi, koje trenutačno imaju fokus prodaje.

Pomoću društvenih medija hotelijeri imaju mogućnost digitalno mapirati putovanje gostiju i kontrolirati evoluciju korisničkog iskustva tijekom vremena (Homburg, Jozić, & Kuehnl, 2017, str. 385). Brojni gosti komuniciraju s hotelom prije nego što se odluče na putovanje. Interakcije koje se odvijaju između hotela i gosta prije, tijekom i nakon kupnje određenog aranžmana generiraju korisne informacije na različitim dodirnim točkama unutar hotelskog poduzeća (recepcija, restoran, rekreativni sadržaji, izleti…). Akumulacija takvih informacija može dovesti do evolucije u odnosu na neke prethodne aranžmane i potaknuti hotelijere da preispitatju svoje resurse i strategije kako bi ostati u toku s evolucijskim ponašanjem potrošača.

1.20.12Prednosti i nedostaci uporabe CRM-a

Provedena istraživanja uglavnom se pozitivno odnose prema CRM-u, posebice napretku i dostignutim rezultatima u promatranom tridesetogodišnjem razdoblju. Svakako da razvoj CRM-a kao snažnog marketinškog alata valja promatrati u kontekstu promjena koje su donijeli širokopojasni internet, svjetlovodi, brojne mobilne aplikacije i razvijena informacijska infrastruktura.

Isto tako, proučavajući dostupne objavljene radove na temu korištenja CRM-a u hotelskoj industriji, mogu se izdvojiti neke dileme koje potiču na razmišljanje i daljnja istraživanja.

1. Kakva je budućnost široko rasprostranjenih programa lojalnosti? Postoji li neka druga strategija osim programa vjernosti koje menadžeri CRM-a hotelske industrije mogu implementirati?

Naime, programi vjernosti naišli su na široku primjenu u hotelskoj industriji koja koristi programe lojalnosti kao strateško i taktičko sredstvo iz niza razloga, od prikupljanja podataka o korisnicima do nagrađivanja korisnika pri održavanju odnosa s korisnicima. Očigledno je da će i u narednom razdoblju ovi programi dominirati u odnosima hotelijeri – gosti s obzirom na t da dostupna literatura ne spominje alternativne strategije.

2. Budući da je CRM većim dijelom postao usmjeren na softver i tehnologiju, a manje se usredotočio na njegovanje stvarnih odnosa, kakva je budućnost CRM-a u doglednom vremenu?

Prihod od CRM softvera iznosio je 39,5 milijardi dolara u 2017. godini i jedan je od najbrže rastućih tržišta softvera sa stopom rasta od 16% (Gartner, 2018). Tehnologija sve više postaje

glavna tema istraživanja CRM-a u hotelskoj industriji. Iako se korijeni CRM-a nalaze u marketingu, postalo je uobičajeno da ga se povezuje s uporabom tehnologije pa se tako na CRM u mnogim hotelima gleda kao na planiranje resursa (engl. *Enterprise Resource Planning* – ERP) i automatizacija prodaje (engl. *Sales Force Automation* – SFA). Na taj se način, kako navodi Eldridge *(Why the 'R' in CRM Is the Most Important Letter in Customer Experience*, 2018) pojam „odnos" odnosno R (*relationship*) u akronimu CRM, marginalizira i postaje sve više tehnološki i administrativni alat, nego alat za izgradnju odnosa. Učinkovit CRM trebao bi imati veći uvid u ponašanje i sklonosti kupaca. U hotelijerskoj industriji koja se temelji na pružanju usluga i gostoprimstvu ljudska interakcija pružatelja usluge i korisnika je nezamjenjiva. Stoga CRM uključuje i promjene u ponašanju zaposlenika, fokusirajući ih na empatiju i pouzdanost. Budućnost će pokazati u kojoj mjeri tehnologija uspješno može zamijeniti ljudsku interakciju.

3. Postoji li tamna strana CRM-a? Ili CRM uvijek postiže pozitivne rezultate?

CRM se u hotelijerskoj industriji u objavljenoj literaturi ocjenjuje kao vrlo pozitivan alat koji proizvodi dobre rezultate. Međutim pozornost privlači Edingerov članak objavljen u *Harvard Business Reviewu* (*Why CRM Projects Fail and How to Make Them More Successful*, 2018), koji ističe da jedna trećina svih CRM projekata propada. Kao razlog se navodi pogrešna primjena jer je mnoge organizacije koriste za izvještavanje i nadgledanje, a ne stvaranje poboljšanja u prodajnom procesu. Postoji još napisa o neuspjesima implementacije CRM-a, ali nema nijednog znanstvenog ili stručnog članka koji bi to potvrdio.

4. Postoji li jasno razgraničenje o benefitima korištenje CRM-a od drugih marketinških aktivnosti hotelskog poduzeća?

CRM je važan dio hotelijerske industrije i kao takav značajno doprinosi ukupnom prihodu nekog hotelskog poduzeća. Međutim malo je istraživanja provedeno koliko CRM participira u ostvarenim rezultatima. Učinak CRM-a može se analizirati u strukturi ukupnog poslovnog učinka, povratu ulaganja u odnosu na investiranje u CRM i lojalnost gostiju. Uglavnom su te analize kvalitativnog karaktera jer je teško mjerljiv učinak CRM-a na lojalnost kao apstraktnu kategoriju. Međutim poznati su troškovi implementacije CRM-a u poslovni sustav, troškovi održavanja i unaprjeđenja. Da se radi o milijunskim iznosima potvrdilo je istraživanje koje su 2011. godine proveli Shanshan, Wilco, i Eric *(A study of hotel frequent-guest programs: Benefits and costs*). Isplate li se ta ulaganja i koliko može se samo pretpostavljati, ali i ustvrditi

da zasigurno postižu višestruki povrat, što proizlazi iz činjenice kako programi lojalnosti gostiju djeluju. Vjerojatno je i da postoji sinergijski učinak drugih programa odjela marketinga, koji također ima troškove za promociju hotela kao brenda.

Zaključno, ne postoji jasno razgraničenje o tome imaju li CRM ili klasični marketinški alati presudan utjecaj na nove generacije korisnika i kome se uspjeh ili neuspjeh može pripisati.

1.21 Integrirani CRM i upravljanje prihodima

U sklopu razmatranja mogućeg integriranja procesa upravljanja odnosima s gostima i upravljanja prihodima (engl. *Revenue Management* – RM) u kontekstu strateškog promišljanja hotelskog okruženja, potrebno je odrediti prema kome usmjeriti djelovanje CRM-a i kakav učinak to ima na prihode.

Jedna je od funkcija CRM-a rangiranje gostiju. Iako tradicija gostoprimstva nalaže da je potrebno svakom gostu pružiti najbolju uslugu, to u praksi i nije jednostavno postići. To automatski ne podrazumijeva da bi neki kupci trebali dobiti lošu uslugu, ali to, s obzirom na ograničenja resursa za mnoge hotele, predstavlja problem jer su gosti ti koji generiraju profit.

Uvriježeno je uvjerenje kako su lojalni gosti najprofitabilniji potrošači i hotelsko poduzeće koštaju manje za usluživanje, obično su spremni platiti više od ostalih gostiju i generiraju nove goste putem preporuka od usta do usta (Reinartz & Kumar, 2002, str. 5). Te prednosti se navode kao temelj za poticanje inicijative ka pridobivanju lojalnog gosta, međutim jedini su dokumentirani i empirijski dokazani pokazatelji – financijski rezultati, odnosno ostvareni prihod od „lojalnog gosta“. Stoga, kako smatraju Reinartz i Kumar *(The mismanagement of customer loyalty*, 2002, str. 6), potrebno je izmjeriti odnos između lojalnosti i profitabilnosti kako bi se bolje identificiralo goste na koje se treba usredotočiti.

1.21.1 Mjera lojalnosti

Struktura podatkovne baze lojalnih kupaca hotelskog poduzeća ovisi o tome kako je lojalnost determinirana. Lojalnost gostiju općenito se određuje prema njegovu ponašanju ili stavu.

Mjere lojalnosti prema ponašanju uključuju obujam i učestalost dolazaka tijekom vremena, potrošnji proizvoda i usluga u destinaciji te vjerojatnost ponovljenog dolaska. Lojalnost prema stavu može se jednostavno mjeriti prema odnosu gosta i hotela. Kod mjerenja lojalnosti poželjno je (Noone, Kimes, & Renaghan, 2003, str. 8) dobiti dvodimenzionalni prikaz lojalnosti, koji uključuje ponašanje i stav. Razvoj matrice lojalnosti hotelskom poduzeću će omogućiti segmentiranje kupaca prema stupnju lojalnosti: 1) istinito, 2) latentno i 3) lažno. Tipologija odanosti gosta pružatelju usluga predočava se narednom slikom.

Slika 30. Matrica lojalnosti



Izvor: prema Noone, Kimes, i Renaghan, *Integrating Customer Relationship Management and Revenue Management: A Hotel Perspective*, 2003, str. 9.

Neki hoteli koriste članstvo u svojem programu vjernosti kao mjerilo lojalnosti. To, međutim, vjerojatno nije odgovarajuća mjera jer članovi ne mogu činiti reprezentativni uzorak svih lojalnih gostiju, a pored toga učešće u programu vjernosti ne znači lojalnost jer gost možda samo trenutačno koristi pogodnosti članstva.

Smatra se da je realnija kvantifikacija lojalnosti na osnovu „minulih dolazaka“, odnosno stečene vrijednosti koja se odnose na goste koji dugi niz godina višekratno koriste usluge hotela. Njihov stupanj lojalnosti se ocjenjuje visokim, a prenosi se na njegovu obitelj, prijatelje i poznanike.

Reinartz i Kumar (2002, str. 10) segmentiraju goste u četiri kategorije (pravi prijatelji, školjke, leptiri i stranci) na temelju projiciranog vijeka trajanja koristi, za prepoznavanje odgovarajućih gostiju ciljanih putem CRM-a.

Slika 31. Segmentiranje gostiju prema lojalnosti hotelskom brendu

SEGMENTACIJA GOSTA		
Visoka rentabilnost	**LEPTIRI**	**PRAVI PRIJATELJI**
	• dobra usklađenost ponude hotela i potreba gostiju • visoki profitni potencijal	• dobra usklađenost ponude hotela i potreba gostiju • visok profitni potencijal
	AKTIVNOSTI	AKTIVNOSTI
	• cilj im je postići transakcijsko zadovoljstvo, ali ne i lojalnost prema stavu • umiljati su samo dok su aktivni • ključni je izazov treba li prestati s ulaganjem	• komunicirati dosljedno, ali ne previše često • graditi i lojalnost prema stavu i ponašanju • ugađati takvim gostima, čuvati ih i zadržati
Niska rentabilnost	**STRANCI**	**ŠKOLJKE**
	• slaba je veza između ponude hotela i potrebe gostiju • najmanji profitni potencijal	• ograničena povezanost između ponuda tvrtke i potrebe gostiju • nizak profitni potencijal
	AKTIVNOSTI	AKTIVNOSTI
	• ne treba ulagati u odnose s gostima • realizirati zaradu na svakoj transakciji	• procijeniti značaj i platežne mogućnosti gosta • ako je platežna moć gosta ograničena, treba se fokusirati na dopunsku (*up-selling*) i vezanu (*cross-selling*) prodaju • ako je platežna moć gosta niska, voditi računa o kontroli troškova

Izvor: prema Noone, Kimes, i Renaghan, *Integrating Customer Relationship Management and Revenue Management: A Hotel Perspective*, 2003, str. 11.

Stranci: s obzirom na njihovu nisku profitabilnost i kratko trajanje, mala je vjerojatnost da se gosti u segmentu „stranci“ transformiraju u profitabilne kupce. Hoteli trebaju primijeniti tradicionalne mjere upravljanja prihodima za takve goste. Uz to, nije potrebno ulagati u promociju za ovaj segment jer povrat ulaganja nije vjerojatan.

Školjke: za ovaj segment gostiju prikladan je tradicionalan način upravljanja prihodima. Hoteli ne bi trebali tražiti održavanje odnosa nudeći programe lojalnosti, ali je poželjno nuditi pogodnosti (u razdoblju mrtve sezone). Ove aktivnosti odnose se na one goste s ograničenom platežnom sposobnošću kako bi ih potaknuli na veću potrošnju i eventualno transformirali u segment „pravi prijatelj“. Temeljem povijesnih podataka o gostu i njegovu obrascu potrošnje, hoteli mogu usmjeriti promotivne aktivnosti na poticanje potrošnje na dodatne usluge. Međutim ako gost troši minimalno zbog nemogućnosti plaćanja, tada hotel ne treba ulagati u takvog gosta.

Leptiri: oni nisu lojalni gosti, već teže transakciji „vrijednost za novac“. Iz tog razloga tradicionalno upravljanje prihoda odgovara ovom segmentu. Pored toga, kratkotrajni programi promocije mogu privući gosta da ponovno dođe u hotel. Ova vrsta promotivnih aktivnosti trebala bi omogućiti hotelu maksimiziranje prihoda od ove grupe kupaca u kratkom vremenu, koliko je i očekivano trajanje njihove veze s hotelom. Kako ovo nisu dugoročni gosti, treba uspostaviti vremensko ograničenje za pogodnosti koje hotel nudi.

Pravi prijatelji: ovaj segment predstavlja najveći profitni potencijal hotela i kao takav jamči isplativost ulaganja. Hoteli bi trebali pokušati izgraditi lojalnost i stavova i ponašanja s pravim prijateljima. Iz tog razloga hoteli bi trebali razmotriti snažne programe lojalnosti temeljene na minulim posjetima.

Prikupljeni podatci bi u sklopu CRM programa trebali omogućiti hotelima da prilagode svoje poticaje u vidu poklona, besplatnih ulaznica za neke dodatne sadržaje (sauna, tenis, golf, bazen...) za lojalne goste. Pored toga, takvim gostima treba jamčiti dostupnost i raspoloživost smještaja u svim hotelima istog hotelskog poduzeća.

Navedena metoda mjerenja lojalnosti je prikladna za CRM sustave jer klasificira goste i predstavlja svojevrsnu kvalifikaciju za ulaz u CRM. Nedostatak takvog načina klasificiranja gostiju je taj što se temelji na subjektivnom stavu koji će programer unijeti u CRM i time možda izgubiti potencijalno lojalnog gosta.

Prikladniji je način brojčane ljestvice šireg raspona (1 – 10) koji ima manji subjektivni utjecaj, što ovisi o isporučitelju programa.

1.22 Društvene mreže u funkciji upravljanja gostima u hotelskoj industriji

Upravljanje odnosima s klijentima u hotelijerstvu mijenja se u skladu s navikama gostiju, inovacijama u informatičkoj tehnologiji, kao i sve prisutnim „pametnim telefonima“ čije se funkcije progresivno mijenjaju te su od primarne funkcije pozivanja i razgovora sve više alat interaktivnog sudjelovanja u razmjeni informacija unutar društvenih mreža.

Upravljati odnosima s klijentima, sada već klasičnim alatima poput telefonskih poziva, elektroničke pošte i SMS poruka, teško može biti uspješno ako nije integrirano u sustav neke od društvenih mreža. „Besplatne“ inačice telefoniranja poput Vibera, WhatsAppa, Facebook

Messengera i drugih preuzele su ulogu telefoniranja, a nekad moćne telefonske kompanije postaju još moćniji mrežni poslužitelji. Svako zaostajanje, odnosno nepravovremeno ažuriranje i nadopunjavanje najnovijim informacijama (engl. *Update & Upgrade*), iskoristit će konkurencija. Stoga je, kako navode Dewnarain, Ramkissoon i Mavondo (2019, str. 1), nadasve važno spoznati spremnost organizacijske kulture u provođenju strategije upravljanja odnosima s klijentima.

1.22.1 Uloga društvenih mreža u razvoju odnosa sa kupcima u turizmu

Društvene mreže su po svojoj sekundarnoj namjeni snažan marketinški kanal, a primarno su izvor njihova financiranja. Međutim društvena mreža je višekanalni sustav koji i najbolji marketinški potez može pretvoriti u fijasko, ako se zanemari činjenica da je WOM[4] preporuka prijatelja (pratitelja) najvažniji izvor informacija. Tijekom svojeg razvoja društvene su mreže bile izložene brojnim reklamnim porukama, negativnim reklamama i izmišljenim vijestima od korisnika s lažnim profilima. S vremenom je kultura ophođenja na društvenim mrežama napredovala, a administratori (programske aplikacije) uvelike sprječavaju, odnosno blokiraju korisnike prijavljene za širenje negativne propagande. Pojavnost nelojalne ili zlonamjerne konkurencije teško je suzbiti, a utjecaj lažnih poruka još je uvijek značajan.

Stoga se odnos s klijentima preko društvenih mreža suzuje na „prijatelje“ i „pratitelje“, a širi se isključivo pozitivnim porukama.

Svaka pojedinačna interakcija između nekog turističkog subjekta i korisnika unutar društvene mreže, kako navode Payne i Flow (2013, str. 173), „znači ujedno i obavljanje milijun interakcija između kupaca, koje se temelje na provođenju društvenog koncepta upravljanja odnosima sa kupcima (engl. *social* CRM)“.

Usporedno je razvojem informacijske tehnologije i koncept upravljanja odnosima s kupcima – CRM pretrpio veliku promjenu iz strategije koja je bile usredotočena isključivo na uspostavljanje financijskih obveza s klijentima, u strategiju koja promiče i transakcijske i

[4] Usmena preporuka ili model „od usta do usta“ (engl. *word of mouth* – WOM) oblik je osobne i neformalne komunikacije koji označava prenošenje pozitivnog ili negativnog iskustva kupaca, kao i davanje preporuka drugim potencijalnim kupcima.

interakcijske odnose sa kupcima. To je stvorilo novi oblik CRM-a, koji je poznat pod nazivom socijalno (društveno) upravljanje odnosima s kupcima (SCRM) ili CRM 2.0.

SCRM tako postaje konceptualni model za upravljanje odnosima između kupaca/korisnika, društvenih medija, tehnologije, angažmana kupaca, pozitivnih riječi i lojalnosti brendu (Dewnarain, Ramkissoon, & Mavondo, *Social customer relationship management: An integrated conceptual framework*, 2018).

Opće prihvaćenim fenomenom pojave društvenih mreža i CRM dobiva svoj socijalni (društveni) prefiks koji se može definirati kao strateško uključivanje korisnika/kupaca putem društvenih medija s ciljem izgradnje povjerenja i lojalnosti brendu (Woodcock, Green, & Starkey, 2011, str. 50).

Međutim samo uključivanje društvenih medija bio je remetilački odnos tradicionalnom pristupu tvrtka – kupac s obzirom na to da je kupac/korisnik postao putem društvenih medija uključen u proces stvaranja vrijednosti putem recenzija ili u obliku korisničkog sadržaja.

Kupci postaju sve informiraniji što su više izloženi Facebooku, TripAdvisoru ili drugim mrežama, multiplicirajući kanale kupovanja putovanja i korištenja odmora.

1.22.2 Tehnologija društvenih medija

Društveni mediji (SM) definirani su kao „skupina internetskih aplikacija koje se temelje na ideološkim i tehnološkim osnovama Weba 2.0, a koji omogućuju kreiranje i razmjenu sadržaja koji je stvorio korisnik“ (Kaplan & Haenlein, 2012). Društveni mediji ne zamjenjuju tradicionalne CRM sustave, ali stvaraju mogućnosti angažmana za male, srednje i velike tvrtke putem relacijskih procesa razmjene informacija, koji se odvijaju između hotela i gostiju ili putem komunikacije između gostiju i njihovih „prijatelja“ ili „pratitelja“.

Dosadašnja su istraživanja učinaka društvenih medija na upravljanje odnosima s korisnicima usluga uglavnom usredotočena na prednosti i izazove korištenja društvenih mreža, zapostavljajući ulogu i karakteristike zaposlenika hotelske industrije. Naime, komuniciranje putem društvenih medija sve više zapostavlja interakciju licem u lice, gdje do izražaja dolazi osobnost, kultura odijevanja i ophođenja hotelskih namještenika, što se ne može lako premostiti komunikacijom na kanalima društvenih medija.

Veliki rast korisnika društvenih medija omogućen je razvojem tehnologija (Web 2.0), što čini jedinstveno korisničko iskustvo. Kad prolazi kroz proces odlučivanja potrošač koristi društvene medije kako bi doznao iskustva drugih, savjete i kritike, što u konačnici može utjecati na njegovu odluku. To otvara prostor za „korisnički angažman" koji aktivno učestvuje u kreiranju svojeg odmora, smještaja, načina putovanja, odabira aktivnosti i sl.

Di Gangi i Wasko (*Social media engagement theory: Exploring the influence of user engagement on social media usage*) istraživali su čimbenike korisničkog angažmana i društvenih medija te utvrdili da transparentnost prisutna na društvenim mrežama ipak nije toliko značajna kao mišljenja prijatelja ili rodbine. Korisnici društvenih medija su evoluirali u svojim zahtjevima i pokazuju se rizičnima za hotelijere jer neprestano traže nova iskustva. Otuda i mogućnost hotelijerima da komuniciraju s potencijalnim i postojećim gostima na kanalima društvenih medija poput Facebooka ili Instagrama, gdje mogu generirati ideje za privlačenja gostiju i razvijanju dugoročnih odnosa.

Razvidno je da će nove tehnologije posredstvom kanala na društvenim mrežama djelovati kao ključni pokretači promjena u hotelijerstvu kada su integrirani s CRM procesima.

1.22.3 Društveni mediji i angažman gosta

Promatrano sa strateškog stajališta, angažman se može definirati i kao korisničko iskustvo koje može „omogućiti hotelijerima da izgrade dublju, smisleniju i održivu interakcije između hotela i njegovih gostiju ili vanjskih dionika" (Sashi, 2012, str. 255). Kad se gost poistovjećuje s brendom hotelske kuće, vjerojatno je da će se pojačano angažirati na različitim mrežnim kanalima bilo u obliku stvaranja sadržaja, bilo putem komentara na objave drugih korisnika. Korisnici mogu jednostavno nadgledati angažman kupaca, promatrajući učestalost dolazaka tijekom vremena, doprinos razvoju turističkog proizvoda kroz generiranje ideja, broj priča koje je gost stvorio ili podijelio, ocjena zadovoljstva koja pružaju gosti na mreži, a to može zauzvrat obogatiti menadžere zanimljivim informacijama o svojem brendu.

Društveni mediji koji omogućuju angažman gostiju nedovoljno su istražena tema u hotelskoj industriji s obzirom na to da se većina radova usredotočuje na korištenje društvenih medija za postizanje kratkoročnih ciljeva prodaje, a ne odanosti prema brendu. Društveni mediji preispituju poslovne procese, olakšavajući dvosmjernu komunikaciju između gosta i davatelja

usluga. Ovakav odmak od tradicionalnog načina poslovanja vjerojatno će inicirati prilike i izazove u hotelskoj industriji.

Sposobnost menadžera hotelske industrije da upravljaju interaktivnim značajkama društvenih medija u marketingu odnosa može im omogućiti uspostavljanje odnosa s postojećim i potencijalnim gostima.

Koncentracija znanja i resursa temeljni je preduvjet za dugoročno poslovanje hotelskog poduzeća. Internetske interakcije generiraju velike količine informacija, koje, ako se kvalitetno procesuiraju, zasigurno mogu rezultirati rastom vrijednosti hotelskog brenda. Međutim vrlo je malo hotelskih tvrtki razumjelo prednosti CRM-a kao pokretača angažmana gostiju kada je integriran s platformama društvenih medija.

1.22.4 Angažman gosta i usmena predaja

Kada se putnik/turist odluči otputovati na neko novo, njemu nepoznato odredište, zasigurno promišlja o svojem smještaju. Načini na koji će se informirati su mnogostruki, od prepuštanja organizacije smještanja nekoj od profesionalnih agencija, preko vlastitog angažmana „surfanjem po netu“ do konzultacija s prijateljima ili rodbinom. To podrazumijeva verbalnu komunikaciju, formalnu ili neformalnu, a koja u konačnici rezultira odabirom smještaja koji je po nekom atributu važniji od ostalih. Ovakav oblik marketinga naziva se „marketing usmene predaje“ (engl. *Word-of-Mouth* – WOM marketing). Osnovna je prednost ovog oblika marketinga što predstavlja važan čimbenik procesa odlučivanja potrošača, a direktan je trošak minimalan. Naravno da je, kako navode Cantallops i Salvi (2014, str. 41), bilo potrebno uložiti mnogo truda i znanja kako bi određeni brend postao djelom usmene predaje, pa se zaključuje kako je trošak WOM marketinga inkorporiran negdje u „minulom radu“ stvaranja brenda.

Sukladno razvoju tehnologije i elektroničkih medija, verbalna komunikacija prelazi u elektroničku komunikaciju, a WOM marketing dobiva prefiks „e“ i postaje eWOM marketing, koji je u društvenim medijima prisutan u vidu mrežnih recenzija, bloga, javnim ili inbox preporukama, razgovorima, dijeljenjima i sl.

Usmena je predaja tema kojoj se u hotelskoj industriji pridaje potrebna pozornost zbog svoje sposobnosti brzog i praktički nezaustavljivog širenja. Posebice je rizičan oblik lažnih profila, koji mogu naškoditi reputaciji hotela ako proizvode negativne komentare.

Ovaj je problem donekle suzbijen pojavom društvenog umrežavanja mrežnih mjesta koja pozivaju korisnike da stvore profil prije interakcije s drugim korisnicima, čime je obnovljena priroda komunikacije licem u lice. Tzv. eWOM može imati oblik mrežne recenzije potrošača, u kojima gosti dijele svoje mišljenje o proizvodima i uslugama na temelju njihovog osobnog iskustva. Druga vrsta eWOM-a je viralno oglašavanje, koje uključuje i internetske videozapise koji se mogu dijeliti, odnosno širiti mrežom i putem *peer-to-peer* dijeljenja, što onemogućuje njihovu kontrolu (Belch, Belch, Kerr, & Powell, 2014).

1.22.5 Vjernost hotelskom brendu

Babin i Harris (2015) smatraju kako su jednokratni transakcijski odnosi s gostima, koji su prevladavali u 20. stoljeću, danas postali nebitni. Dok su određeni kupci nove generacije „milenijci“ skloni eksperimentirati s brendovima, drugi imaju snažnu želju za stvaranjem trajnih odnosa s određenim hotelima, a ne za korištenje jednokratne usluge. To ukazuje na to da postoji hitna potreba da menadžeri hotelskih marketinga teže ka kvalitetnim odnosima s ovakvom vrstom gostiju (Ong, Lee, & Ramayah, 2018, str. 4). Vrijedi napomenuti da će kvaliteta odnosa porasti onda kada se pojavi potreba za korištenjem usluge te se gost automatizmom vraća poznatom brendu. Štoviše, snažna kvaliteta odnosa podrazumijeva da hotelsko poduzeće ima veće šanse za proširivanje svog portfelja proizvoda na gosta koji je lojalan brendu. Za razliku od gosta koji je sklon promjeni brenda, lojalan gost će u postupak donošenja odluke o korištenju usluge uvažavati vrijednosti prethodno korištene usluge, smatrajući da u nekom drugom hotelu (brendu) neće imati takvu kvalitetu. Dakle, dobar indeks kvalitete odnosa dovest će do posvećenosti brendu, koja je nužna za postizanje lojalnosti.

Angažman korisnika u sektoru turizma pokazuje visoku razinu društvenih interakcija putem *web*-aplikacija poput Facebooka i Twittera, čime može pozitivno utjecati na povjerenje, ocjenu branda i lojalnost *(Dewnarain, Ramkissoon, & Mavondo, Social customer relationship management in the hospitality industry*, 2019, str. 10).

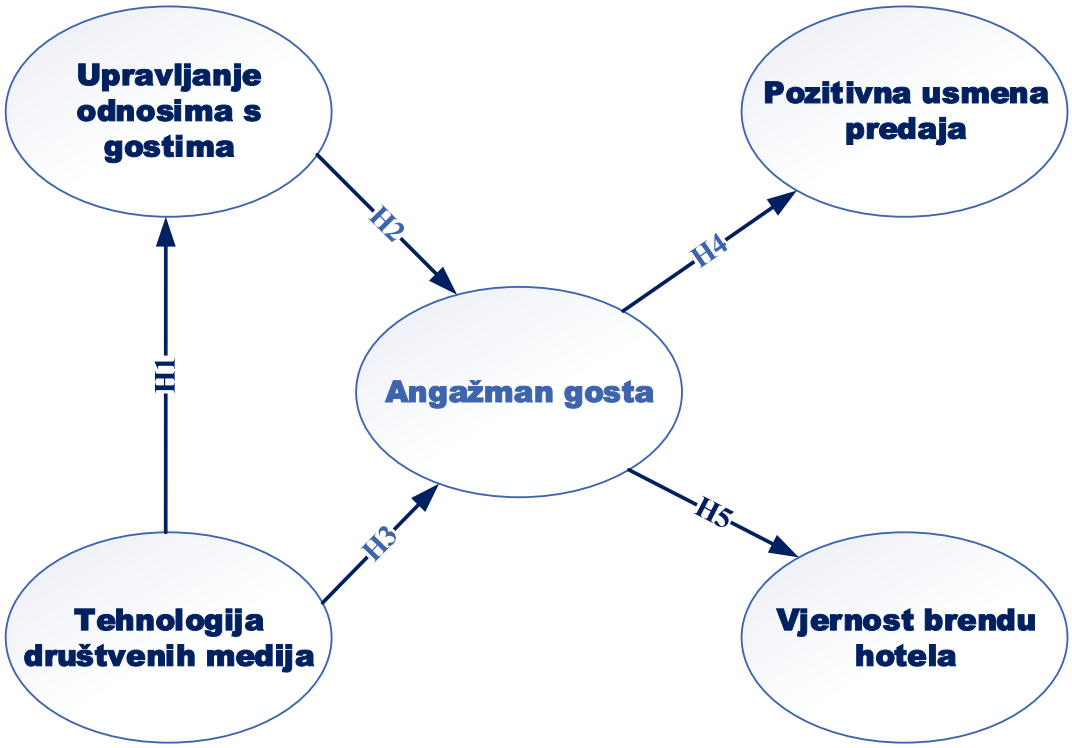
Upotreba društvenih medija je, kako navode Leung, Bai, i Stahura (Leung, Bai, & Stahura, 2015, str. 152), postala pravilo u nekim turističkim organizacijama kao što su Expedia, Lonely Planet and Travelocity, ali i ostale platforme društvenih medija poput Trip Advisora, a Booking.com i Airbnb mogu djelovati kao glavni čimbenici utjecaja u procesu donošenja odluke o putovanju i odabiru određenog hotelskog brenda.

Dakle, SCRM može dati ogromne mogućnosti za hotelske tvrtke aktivnim angažiranjem s gostima, uključujući ih u proces stvaranja vrijednosti. Internetske interakcije s gostima rezultirat će korisničkim sadržajem čak i prije nego što gost dođe u hotel, što znači da razmjena informacija između hotelskog poduzeća i gosta može dovesti do zajedničkog stvaranja vrijednosti, što može rezultirati dugotrajnom vjernošću brendu.

1.22.6 Konceptualni model SCRM-a

Konceptualni su modeli značajni za integraciju i ilustraciju postojećeg sintetiziranog znanja o angažmanu korisnika na društvenim medijima. Svrha konceptualnog modela je „spojiti spoznaje iz širokog spektra izvora i podržati informirano odlučivanje o uvođenju SCRM-a u hotelsku industriju“ *(Dewnarain, Ramkissoon, & Mavondo, Social customer relationship management in the hospitality industry*, 2019, str. 11). Narednom slikom prezentira se okvir SCRM-a (Dewnarain, Ramkissoon, & Mavondo, *Social customer relationship management: An integrated conceptual framework*, 2018, str. 11).

Slika 32. Predloženi okvir SCRM-a



Izvor: Dewnarain, Ramkissoon i Mavondo, *Social customer relationship management: An integrated conceptual framework*, 2018, str. 11.

Predloženi model sastoji se od CRM dimenzije i tehnologije društvenih medija kao dvaju konstrukata koja svojim djelovanjem omogućuju angažman kupaca. Štoviše, prikazuje pozitivnu usmenu predaju i vjernost brendu hotela kao ishod angažmana na platformama društvenih medija. Platforme društvenih medija omogućuju hotelskom poduzeću da se poveže i komunicira s postojećim i potencijalnim gostima.

Može se ustvrditi kako je integracija društvenih medija, uz upravljanje odnosima s kupcima, može promovirati angažman kupaca, što je bitno za povećanje lojalnosti brendu bilo ponovljenim dolaskom gosta u hotel ili u obliku pozitivne usmene predaje.

Angažiranje gostiju dovodi do procesa koprodukcije vrijednosti, koji može utjecati na ishode odnosa s kupcima, poput posvećenosti marki i zagovaranja. Područje marketinške komunikacije se mijenja, pa su tako „digitalni korisnici“ trenutačno u prednosti.

Ovaj je predloženi model prilagođen za promjenu u ponašanju potrošača i, također, u svrhu zadovoljavanja evoluirajućih potreba tržišta.

EMPIRIJSKO ISTRAŽIVANJE OPERATIVNE EFIKASNOSTI I INOVATIVNOSTI PRIMJENE ICT TEHNOLOGIJE U POSLOVANJU HOTELSKIH PODUZEĆA U REPUBLICI HRVATSKOJ

U empirijskom se dijelu rada tražila potvrda učinaka koje hotelskoj industriji pružaju suvremena ICT rješenja. Kako i koliko se ona koriste u hrvatskom hotelijerstvu, kako relevantni čimbenici ocjenjuju primjenu i učinkovitost informatičko-komunikacijske tehnologije, o čemu ovisi implementacija umjetne inteligencije u hotelijerstvu i kakva je po njihovu mišljenju perspektiva korištenja naprednih informatičkih sustava i njihova uloga u razvoju hotelskih usluga. Nadalje, vrednovanjem elemenata razvoja ICT-ja u aktualnom trenutku hrvatskog hotelijerstva te procjenom njihovih vrijednosti za narednih pet godina omogućit će se formiranje modela razvoja ICT-ja u hotelijerstvu u perspektivi.

U tom je smislu provedeno anketiranje ***poznavatelja*** putem anketnog upitnika.

1.23 Metodologija istraživanja

Istraživanje je provedeno tijekom rujna i listopada 2019. godine osobnim intervjuiranjem te anketiranjem posredstvom e-pošte na poznate adresante poznavatelja, odnosno eksperata relevantnih za temu istraživanja doktorskog rada.

Uzorak su činili aktivni dionici upravljanja hotelskim poslovanjem u Republici Hrvatskoj. Konkretno, intervjuirani su direktori hotelskih poduzeća, direktori marketinga i direktori prodaje, odnosno šefovi recepcije kao osobe koje se u svojem redovnom poslovanju koriste informacijskim tehnologijama i koji poznaju sve prednosti i nedostatke kojima ICT utječe na obavljanje njihova posla.

Anketni je upitnik kreiran na način da se od ispitanika tražilo da dodjeljivanjem ocjena izraze svoje stavove o elementima integriranih komunikacijskih usluga u hotelu, ocijene funkcije CRM sustava i njegove korisničke podrške, ocijene postojeće i percipiraju buduće razvojne elemente CRM-a te iznesu mišljenja o postojećem stanju korištenja ICT-ja, njihove doprinose učinkovitosti poslovanja i konkurentnosti na tržištu.

Kako bi se dostigla vjerodostojnost uzorka, nastojalo se u odgovarajućem omjeru osigurati zastupljenost ispitanika iz hotela na otocima, u priobalju, na kontinentu te u gradovima. Isto tako bilo je potrebno u odgovarajućem omjeru koristiti ispitanike iz malih (do 100 soba),

srednjih (od 100 do 200 soba) i velikih hotela (preko 200 soba). Nadalje, bilo je potrebno osigurati i podjednaku zastupljenost prema preferencijalnim oblicima smještaja (odmor, sport i zabava, zdravlje i *wellness* te kongres i posao) te prema vrsti poslovanja (sezonski, cjelogodišnji, specijalizirani i apartmanski).

Kontrolne varijable su starosna dob, radno iskustvo i stupanj obrazovanja, mjerni instrument je upitnik s pitanjima zatvorenog tipa stupnjevanima Likertovom ljestvicom, a pouzdanost se provjerava izračunavanjem *Chrombach alphe* (SPSS 24).

Problem istraživanja koji je uvijek prisutan prilikom provođenja ankete putem pošte (e-pošte) jest činjenica da pojedini ispitanici, iako je anonimnost naznačena i zagarantirana, nevoljko odstupaju od deklariranih stavova koje zastupaju njihove ustanove ili poslodavci, što upućuje da neka odstupanja valja prihvatiti s određenom rezervom.

Svrha istraživanja jest temeljem prikupljenih odgovora na odabranom uzorku i provedenoj statističkoj analizi i raspravi donijeti argumentirane zaključke o stupnju involviranosti ICT-ja u poslovanje hotela, vrednovanje učinaka integriranih komunikacijskih usluga u hotelu, ocjenu prihvatljivosti CRM-a u hotelskom poslovanju te odgovarajućim modelom procijeniti razvojne mogućnosti korištenja CRM-a u perspektivi.

1.24 Opći podatci o uzorku ispitanika

Područje istraživanja operativne efikasnosti i inovativnosti primjene ICT tehnologije u poslovanju hotelskih poduzeća u Republici Hrvatskoj usko stručno je područje upravljanja hotelskim sustavom primjenom informacijske tehnologije. Stoga je i odabran uzorak ispitanika od kojih su se tražili odgovori na pitanja o elementima integriranih komunikacijskih usluga u hotelu, ocjeni funkcija CRM sustava, mogućnostima razvoja i mišljenja i stavova njegovoj o primjeni, a trebali bi biti stručno upućeni i dobri poznavatelji hotelskog poslovanja.

U tom kontekstu uzorak ispitanika hrvatskih hotela sužen je na hotelski menadžment, odnosno na direktora hotela, direktora marketinga i šefa recepcije (funkcija direktora prodaje). Dakle, radi se o relevantnom uzorku eksperata koji su dobro upućeni u temu istraživanja. Promatranu populaciju činilo je podatcima iz Ministarstva turizma Republike Hrvatske 31. kolovoza 2019. godine 814 hotelskih objekata (hoteli i aparthoteli), anketom je obuhvaćeno 106 hotela, odnosno 13,02%, što čini reprezentativni uzorak, posebice ako se zna da manji hotelski objekti koriste tek osnovne funkcije ICT-ja.

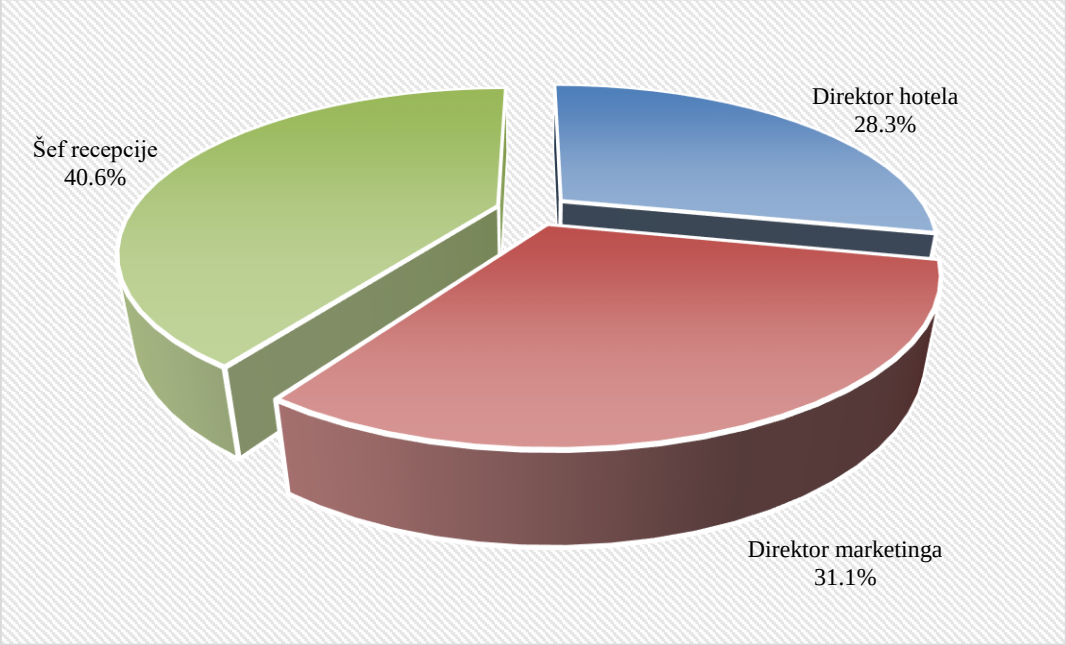
1.24.1 Poslovna funkcija ispitanika

Pitanja su bila upućena dobrim poznavateljima primjene ICT-ja u 106 hotela. Svi ispitanici (100%) dali su važeći odgovor o svojoj poslovnoj funkciji i razvrstani su kako slijedi:

- direktor hotela – 30 ispitanika 28,3%
- direktor marketinga – 33 ispitanika 31,1%
- direktor prodaje (šef recepcije) – 43 ispitanika 40,6%.

Vizualno se frekvencija uzorka prema poslovnoj funkciji predočava narednim grafikonom:

Grafikon 1. Frekvencija uzorka prema poslovnoj funkciji u %



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Iz grafikona 1. je uočljiv ravnomjeran uzorak prema funkcijama koje ispitanici obavljaju u hotelu.

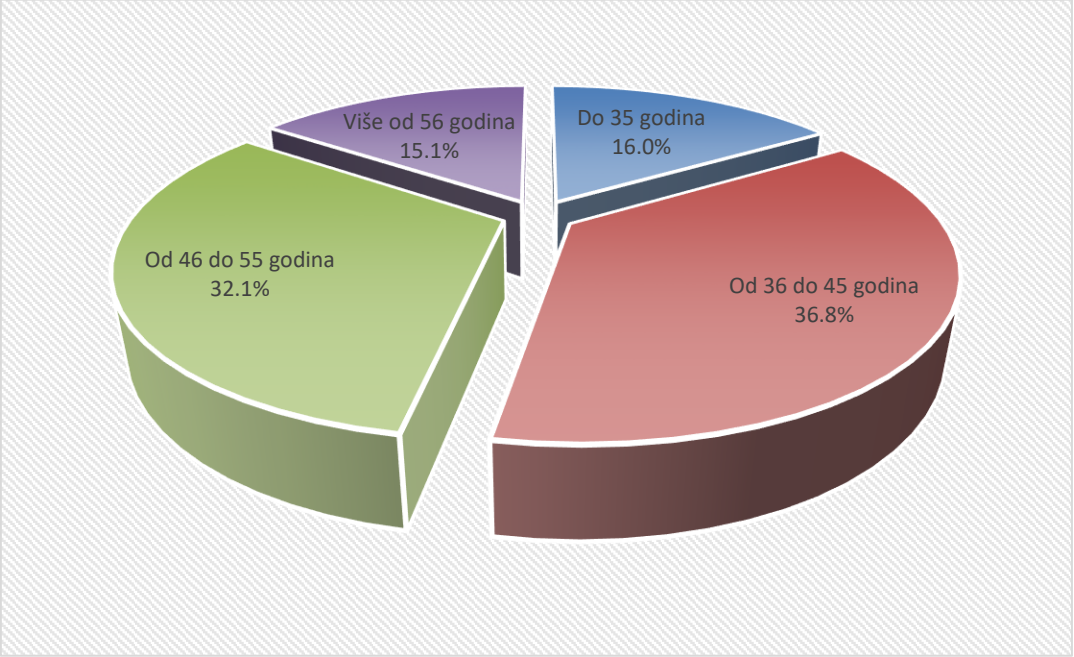
1.24.2 Dob ispitanika

Starosna struktura uzorka je standardan dio analiziranja profila ispitanika i ukazuje na način promišljanja s aspekta dobne zrelosti. Od ukupno 106 ispitanika svi su ispitanici (100%) dali važeći odgovor o svojoj starosnoj dobi. Ispitanici su razvrstani u četiri kategorije kako slijedi:

- do 35 godina – 17 ispitanika (16%)
- od 36 do 45 godina – 39 ispitanika (36,8%)
- od 46 do 55 godina – 34 ispitanika (32,1%) i
- više od 56 godina – 16 ispitanika (15,1%).

Vizualno se frekvencija uzorka prema dobi ispitanika predočava narednim grafikonom.

Grafikon 2. Frekvencija uzorka prema dobi ispitanika u %



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Iz grafikona 2. vidljiva je koncentracija ispitanika u srednjoj životnoj dobi.

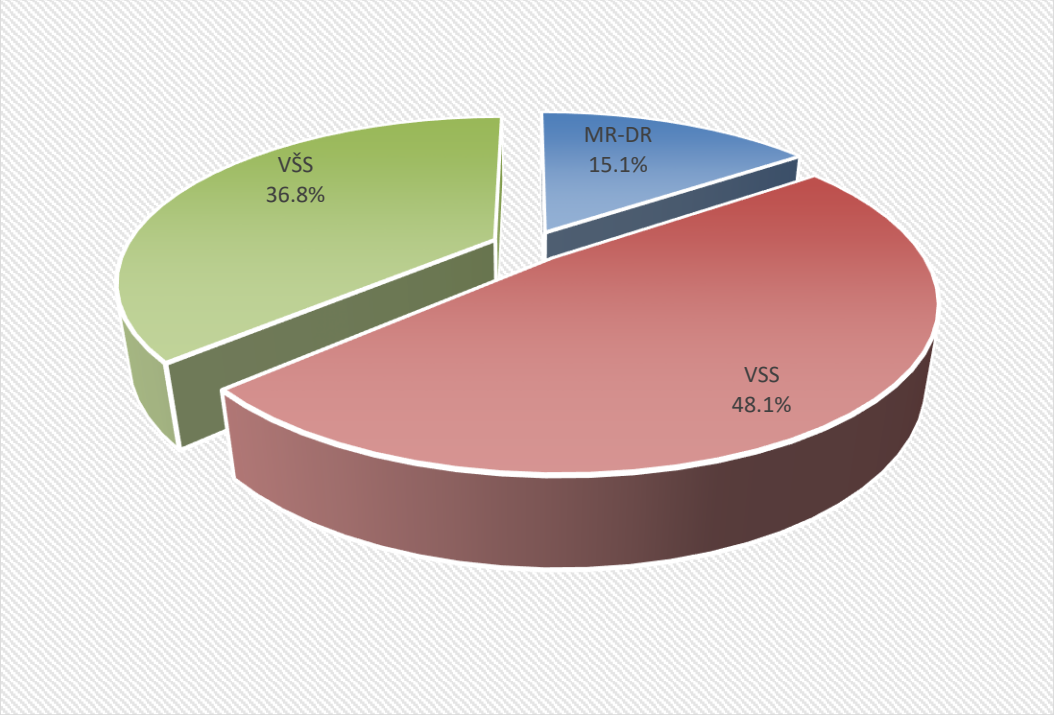
1.24.3 Stupanj obrazovanja ispitanika

Stupanj obrazovanja ispitanika važan je čimbenik prilikom davanja odgovora s obzirom na temu istraživanja koja iziskuje stručnost. Od ukupno 106 ispitanika svi (100%) su se izjasnili o svojem stupnju obrazovanja kako slijedi:

- magistri ili doktori znanosti – 16 ispitanika (15,1%)
- visoko školsko obrazovanje – 51 ispitanik (48,1%)
- viša školska sprema – 39 ispitanika (36,8%).

Vizualno se frekvencija uzorka prema stupnju obrazovanja ispitanika predočava narednim grafikonom.

Grafikon 3. Frekvencija uzorka prema stupnju obrazovanja ispitanika u %



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Iz grafikona 3. je vidljiva koncentracija ispitanika s fakultetskom naobrazbom.

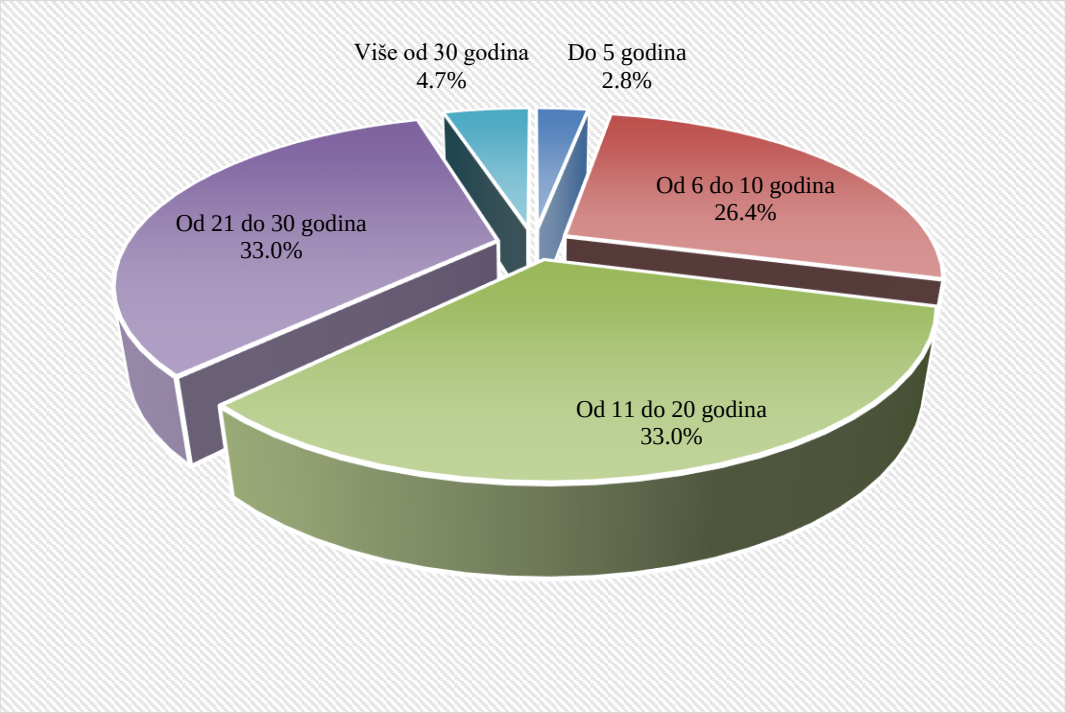
1.24.4 Radno iskustvo ispitanika

U uskoj svezi prethodnim pitanjem, četvrto postavljeno pitanje tražilo je od ispitanika da se izjasne o svom radnom iskustvu u hotelijerstvo. Od 106 ispitanika svi (100%) su se izjasnili o svojem radnom iskustvu kako slijedi:

- do 5 godina – 3 ispitanika (2,8%)
- od 6 do 10 godina – 28 ispitanika (26,4%)
- od 11 do 20 godina – 35 ispitanika (33,0%)
- od 21 do 30 godina – 35 ispitanika (33,0%) i
- više od 30 godina – 5 ispitanika (4,7%).

Vizualno se frekvencija uzorka prema radnom iskustvu ispitanika predočava narednim grafikonom:

Grafikon 4. Frekvencija uzorka prema radnom iskustvu ispitanika u %



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Iz grafikona 4. je vidljivo kako je malen udio ispitanika s najmanje i najviše radnog staža.

1.25 Opći podatci o objektima istraživanja

Objekt istraživanja je hotel. Hotel je objekt u kojemu se gostima obvezno pružaju usluge smještaja i doručka, a mogu se pružati i druge ugostiteljske usluge. Da bi zadovoljio naziv, hotel mora biti usklađen s Pravilnikom o razvrstavanju, kategorizaciji i posebnim standardima ugostiteljskih objekata iz skupine hoteli. Republika Hrvatska zbog svojeg specifičnog zemljopisnog položaja ima hotele na različitim lokacijama o kojima pak ovisi veličina, vrsta i namjena hotela.

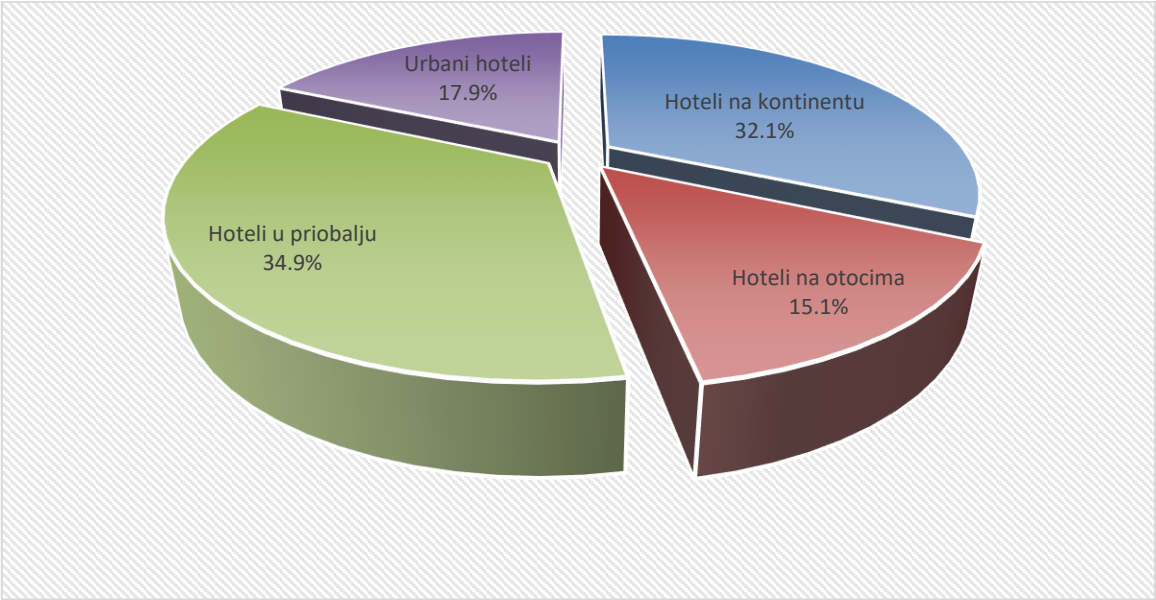
1.25.1 Distribucija uzorka hotela prema lokaciji

Generalno se hoteli prema lokaciji mogu razvrstati kao hoteli u priobalju, na otocima, na kontinentu i urbani. Istraživano je ukupno 106 hotelskih objekata diljem Republike Hrvatske a distribucija je sljedeća:

- hoteli na kontinentu – 34 hotela (32,1%) smještena u središnjem (kontinentalnom) dijelu Hrvatske
- hoteli na otocima – 16 (15,1%)
- hoteli u priobalju – 37 (34,9%)
- urbani hoteli – 19 hotela (17,9%) smještenih u većim gradovima kontinentalne Hrvatske.

Vizualno se raspodjela uzorka hotela prema lokaciji predočava narednim grafikonom:

Grafikon 5. Frekvencija uzorka hotela prema lokaciji u %



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Grafikonom 5. predočava se razdioba lokacija promatranih hotela. Očekivano, s obzirom na turističku orijentaciju Republike Hrvatske veća je zastupljenost hotela u priobalju i na otocima od onih na kontinentu.

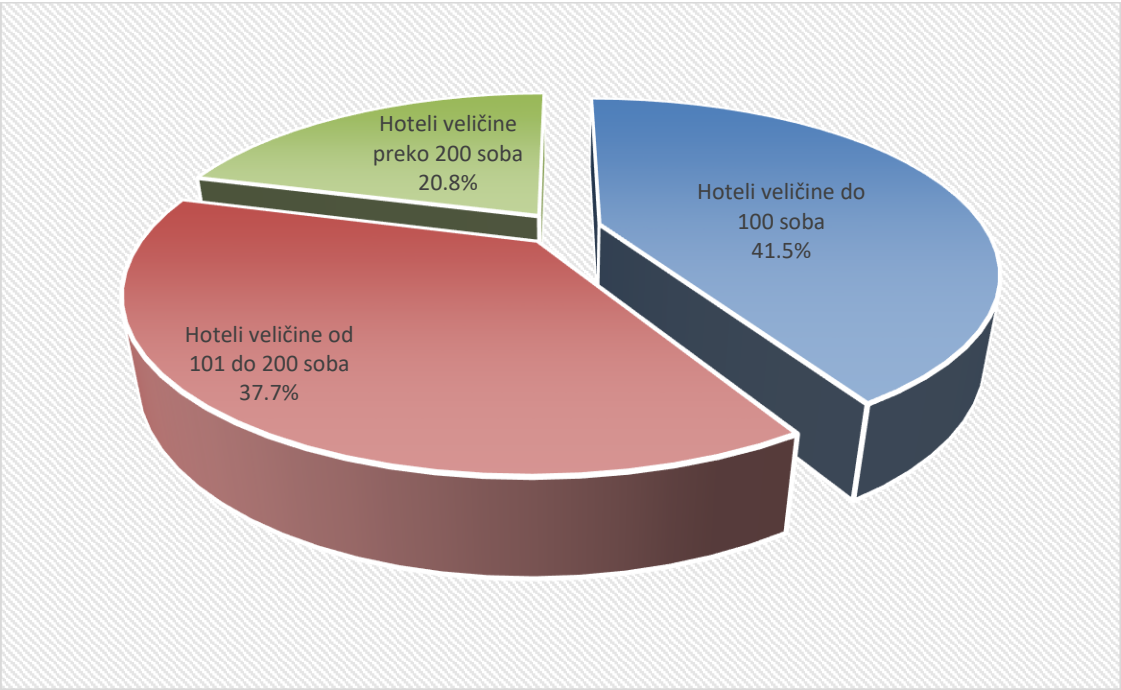
1.25.2 Veličina hotela

Drugi atribut hotela je njegova veličina. Smatra se racionalnim veličinu hotela promatrati u trima kategorijama i to one hotele koji imaju manje od 100 soba, srednje hotele koji imaju između 101 i 200 soba i one velike iznad 200 soba. Primljeni su podatci iz svih 106 hotela (100%) a distribuirani su kako slijedi:

- hoteli veličine do 100 soba – 44 (41,5%)
- hoteli veličine od 101 do 200 soba – 40 (37,7%) i
- hoteli veličine preko 200 soba – 22 (20,8%).

Vizualno se raspodjela uzorka hotela prema veličini predočava narednim grafikonom:

Grafikon 6. Frekvencija uzorka hotela prema veličini u %



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Iz grafikona 6. uočljiva je dominacija malih i srednjih hotela što odgovara promatranoj populaciji hotela u Republici Hrvatskoj.

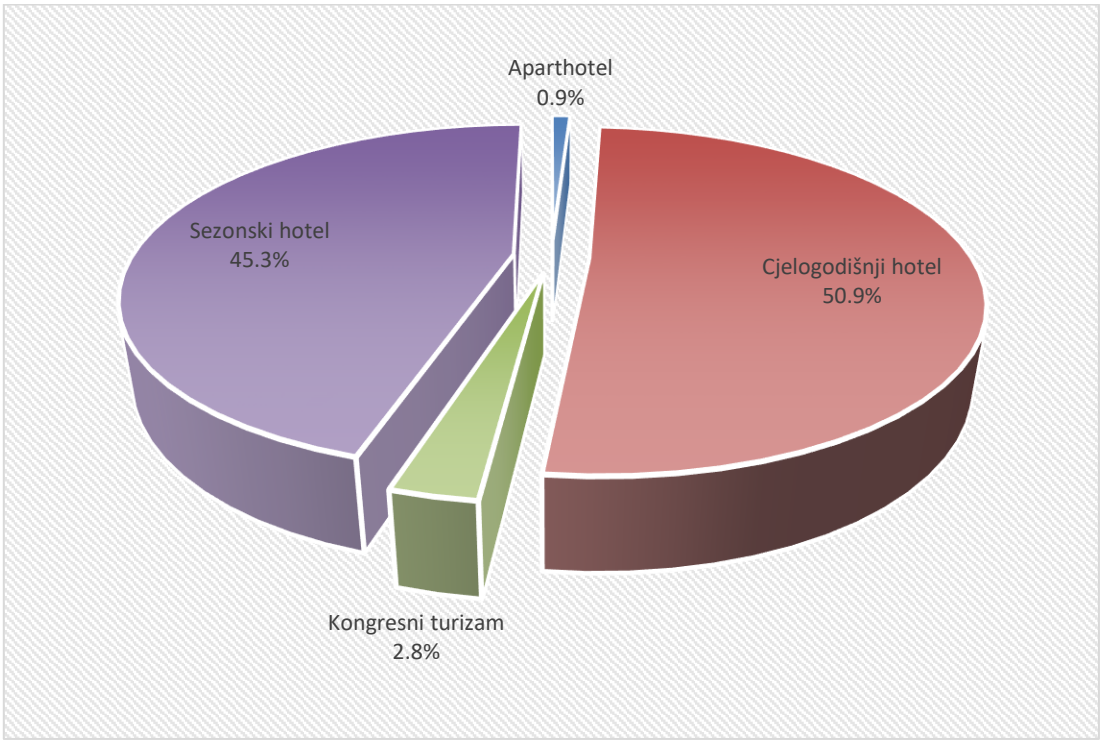
1.25.3 Vrsta hotela prema načinu poslovanja

Prema načinu poslovanja hoteli su za potrebe ovog istraživanja razvrstani kao: hoteli koji posluju tijekom cijele godine, hoteli koji posluju samo u sezoni, hoteli specijalizirani za kongresna događanja i aparthoteli. Primljeni su podatci iz svih 106 hotela (100%) a distribuirani su kako slijedi:

- aparthotel – 1 objekt (0,9%)
- cjelogodišnji hotel – 54 objekta (50,9%)
- kongresni turizam – 3 objekta (2,8%) i
- sezonski hotel – 48 objekata (45,3%).

Vizualno se raspodjela uzorka hotela prema veličini predočava narednim grafikonom:

Grafikon 7. Frekvencija uzorka hotela prema vrsti poslovanja u %



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Promatrano prema poslovanju, kako je to prikazano grafikonom 7., u uzorku prevladavaju dvije vrste hotela i to oni koji posluju tijekom cijele godine (gradski i veća turistička središta) i oni sezonski.

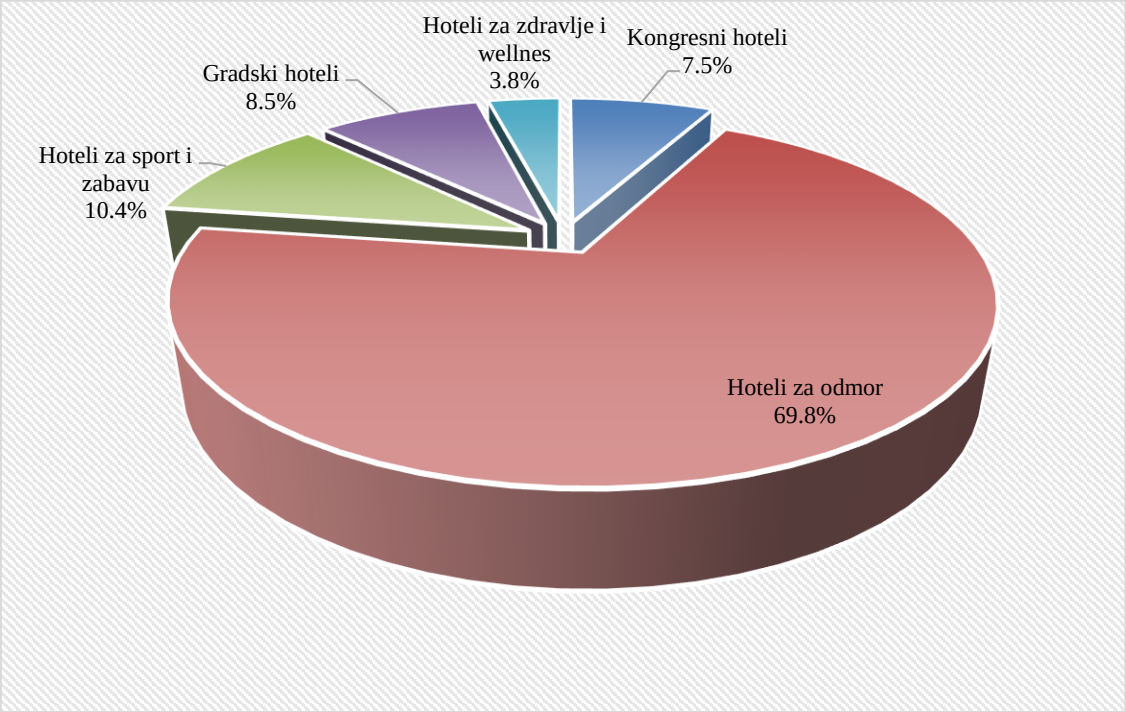
1.25.4 Vrste hotela prema namjeni poslovanja

Četvrti atribut kojim se opisuju objekti je namjena hotela. Prema namjeni su hoteli razvrstani kao: hoteli za odmor, hoteli za sport i zabavu, za zdravlje i *wellness*, za kongrese i posao te urbani hoteli. Primljeni su podatci iz svih 106 hotela (100%) a distribuirani su kako slijedi:

- kongresni hoteli – 8 hotela (7,5%)
- hoteli za odmor – 74 hotela (69,8%)
- hoteli za sport i zabavu – 11 hotela (10,4%)
- gradski hoteli – 9 hotela (8,5%) i
- hoteli za zdravlje i *wellness* – 4 hotela (3,8%).

Vizualno se raspodjela uzorka hotela prema pretežitoj namjeni predočava narednim grafikonom:

Grafikon 8. Frekvencija uzorka hotela prema namjeni poslovanja u %



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Iz grafikona 8. uočljivo je kako u promatranom uzorku prevladavaju hoteli pretežito namijenjeni odmoru gostiju što je karakteristično za turistički orijentirane države poput Hrvatske.

1.26 Ocjena elemenata integriranih informacijsko-komunikacijskih usluga – osnovne usluge

Od ispitanika se tražilo da ocijene postojeće stanje integriranih informacijsko-komunikacijskih elemenata u svojem hotelu. Ocjenjivani elementi jesu: 1) telefonija i telefonske aplikacije, 2) integracija fiksne i mobilne telefonije na razini hotela, 3) hotelski sustav reklamiranja, 4) zabavu za goste kad su u sobama (*entertainment* TV, videosadržaj na zahtjev, igranje, kockanje ili druge igre na sreću, glazba po ukusu gosta i drugi sadržaji), 5) dostup internetu (žicom ili bežično), 6) kontrola ulaza, 7) kontrola i upravljanje minibarom, 8) osvjetljenje (*lighting*), 9) upravljanje energijom, grijanje, ventilacija, klimatizacijski uređaji, 10) sigurnost – vatrodojava i poziv za pomoć, videonadzor te 11) integraciju i korištenje pametnih kartica (*smart card billing*).

Prvi je korak u analizi elemenata ocjenjivanja procjena pouzdanosti mjerne ljestvice. Postavljena je Likertova ljestvica ocjena od 1 do 10 a pouzdanost se provjerava izračunavanjem Chrombach alphe (SPSS 24).

Izračunan Chrombach alpha za analiziranih 11 elemenata iznosi 0,859 što se smatra izvrsnom pouzdanosti.

Analiza ocjena elemenata u nastavku se provodi klasičnim statističkim metodama izračuna aritmetičke sredine, medijana, standardne devijacije, varijance, ravnomjernosti razdiobe (hi kvadrat test) odstupanja od normalne krivulje (Skewness, Kurtosis) rasporeda u percentilima te Bootstrap metodom "pojačavanja" uzorka. Pored tabličnog prezentiranja izračunatih vrijednosti koristit će se i grafički prikaz (histogram).

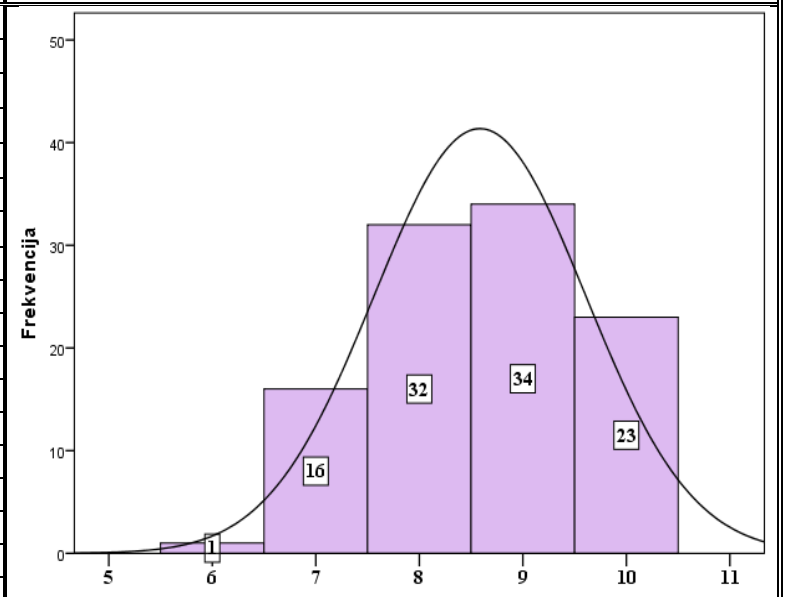
1.26.1 Telefonija i telefonske aplikacije

Prvi element koji je ponuđen na ocjenjivanje ispitanicima odnosio se na kvalitetu telefonije i telefonskih aplikacija u hotelu. Element podrazumijeva da je dostupnost korištenja telefona i

usluga vezanih za telefoniju sukladna zahtjevima suvremenog gosta. To znači da svaka soba ima telefonski priključak za interno i eksterno korištenje, automatiziranu uslugu buđenja i dostave u sobu. Automatiziranu ocjenu zadovoljstva uslugom, pritužbi i reklamacija. Unatoč prevlasti mobilne telefonije nad klasičnom telefonijom gostima i nadalje ova usluga mora biti dostupna posebice zbog interakcije s recepcijom, restoranom ili servisima.

Svi su ispitanici (100%) ocijenili taj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 1. Frekvencija i distribucija ocjena elementa telefonije i telefonskih aplikacija

Telefonija i telefonske aplikacije		**F**	**%**	**Histogram ocjena elementa 1.**
Ocjena	6	1	0,9	
	7	16	15,1	
	8	32	30,2	
	9	34	32,1	
	10	23	21,7	
	Ukupno	106	100,0	
$\bar{X}$			8,5849	
Medijan			9,0	
Mod			9,0	
SD			1,02230	
Varijanca σ^2			1,045	
Raspon			4	
Σ			910	
Skewness			-0,180	
Kurtosis			-0,848	
Percentil	25		8,0	
	50		9,0	
	75		9,0	

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 1. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 6 do 10. Svega je jedan ispitanik (0,9%) dodijelio ocjenu 6 dok su 23 ispitanika (21,7%) dodijelila maksimalnu ocjenu 10. Ocjene 9 i 8 su dominirale (ukupno 62,3%). Histogram 1. jasno predočava kako ocjene elementa telefonije i telefonskih aplikacija prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,180 što ukazuje na slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -0,848 što označava platikurtičnost koja se ogleda u umjerenom grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 2. Bootstrap analiza ocjena elementa telefonije i telefonskih aplikacija

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
Važeći	106	0	0	106	106
Nevažeći	0	0	0	0	0
$\bar{X}$	8,5849	0,0023	0,1015	8,3868	8,7925
Medijan	9	-0,22	0,3966	8	9
SD	1,0223	-0,01062	0,05331	0,91317	1,11306
Varijanca σ^2	1,045	-0,019	0,108	0,834	1,239

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element telefonije i telefonskih aplikacija ocijenili prosječnom ocjenom 8,584 uz standardnu devijaciju od 1,022 i varijancu 1,045. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

Slijedi analiziranje kako su element telefonije i telefonskih aplikacija ocijenili ispitanici s obzirom na: a) poslovnu poziciju i b) lokaciju hotela ispitanika.

a) Distribucija ocjene elementa telefonije i telefonskih aplikacija prema poslovnoj poziciji ispitanika

Poslovna pozicija u hotelu ujedno je i atribut ***poznavatelja*** kojem su upućeni anketni listići. Oni su najmjerodavnije osobe u hotelu kada je u pitanju opće poznavanje operativne efikasnosti i inovativnosti primjene ICT tehnologije u poslovanju hotelskih poduzeća. Svaki od njih ima svoju osobnu percepciju o stanju telefonije i telefonskih aplikacija u "njihovu hotelu" što omogućava realnije sagledavanje stanja ovog elementa u hrvatskim hotelima.

Postavlja se istraživačka hipoteza H_I kako pozicija ispitanika utječe na dodjeljivanje ocjena elementa telefonije i telefonskih aplikacija. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 3. Statistička analiza ocjena elementa telefonije i telefonskih aplikacija prema poziciji ispitanika

Telefonija i telefonske aplikacije

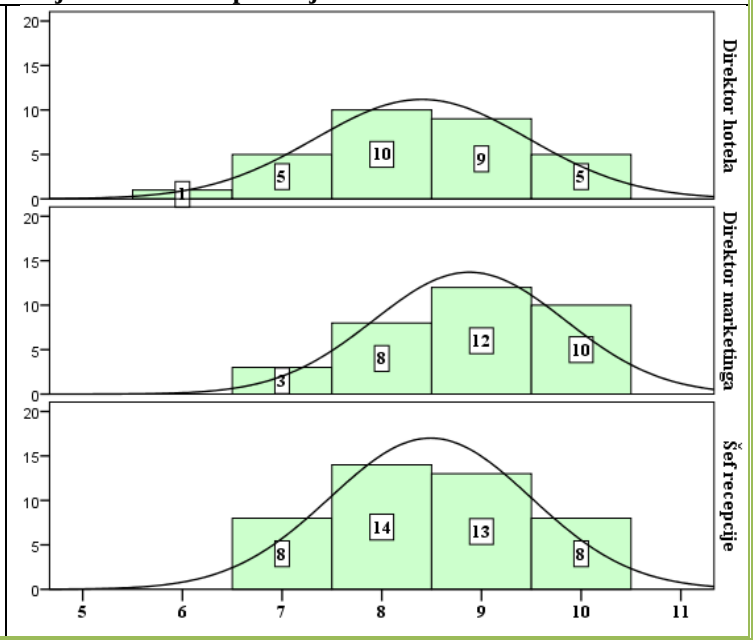
Direktor hotela	$\bar{X}$	8,400
	N	30
Direktor marketinga	$\bar{X}$	8,879
	N	33
Šef recepcije	$\bar{X}$	8,489
	N	43

N = 106

Pearson χ2	**6,227**	**df**	**8**
Omjer vjerojatnosti	6,256		8
Phi	0,242		
Cramer's V	0,171		
Koeficijent kontingencije	0,236		
Tablični χ2	**15,507**		

χ 2 < χ2 tablični 5% sign.

Prihvaća se H₀



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 3. uočljivo je kako je element telefonije i telefonskih aplikacija dobio najviše prosječne ocjene od direktora marketinga. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Hi kvadrat test pokazuje kako pozicija ispitanika nema utjecaj na varijabilnost ocjena čime se odbacuje istraživačka hipoteza H_I i prihvaća nul-hipoteza o nezavisnosti raspodjele ocjena, odnosno njihovoj ravnomjernosti. Omjer vjerojatnosti korespondira s Pearsonovim χ^2 testom. Phi, Cramerov V i koeficijent kontingencije su mjere odstupanja od normalne razdiobe (asimetrije). Ovi se pokazatelji koriste u analizi kako bi se potvrdio ili opovrgnuo utjecaj određenih varijabli (segmenata) na promatrane skupine (faktore). Umjerena vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje.

b) Distribucija ocjene elementa telefonije i telefonskih aplikacija prema lokaciji hotela

Lokacija hotela važan je atribut istraživanja s obzirom na to da još uvijek nije u svim dijelovima Hrvatske razvijena IT infrastruktura. Stoga nisu u jednakoj situaciji urbani hoteli ili hoteli u turistički razvijenom priobalju s onima na otocima ili na kontinentu. Postavlja se istraživačka hipoteza H_I kako lokacija hotela ispitanika utječe na dodjeljivanje ocjena elementa telefonije i

telefonskih aplikacija. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom se složenom tablicom predočavaju rezultati provedene analize.

Tablica 4. Statistička analiza ocjena elementa telefonije i telefonskih aplikacija prema lokaciji hotela ispitanika

Telefonija i telefonske aplikacije

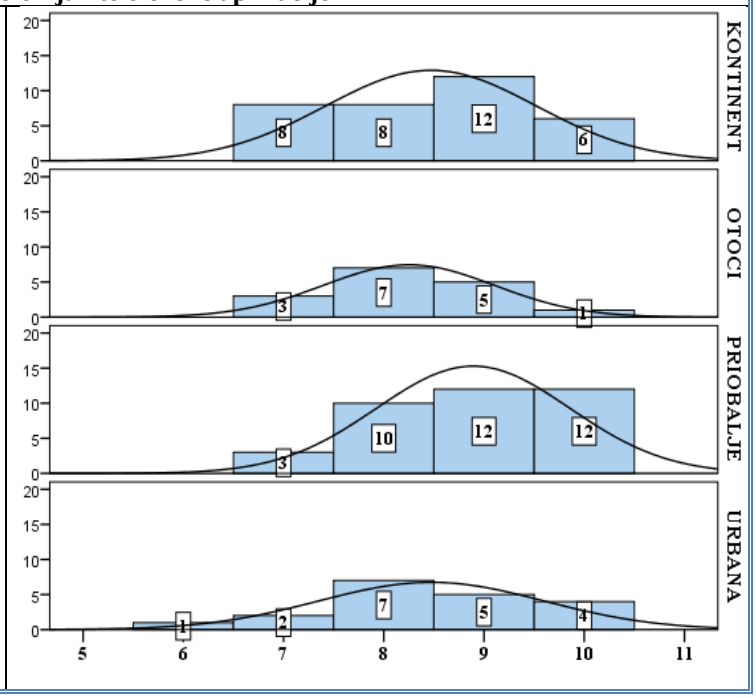
Kontinent	$\bar{X}$	8,471
	N	34
Otoci	$\bar{X}$	8,250
	N	16
Priobalje	$\bar{X}$	8,891
	N	37
Urbani	$\bar{X}$	8,473
	N	19

N = 106

Pearson χ2	**13,954**	**df**	**12**
Omjer vjerojatnosti	13,211	df	12
Phi	0,363		
Cramer's V	0,209		
Koeficijent kontingencije	0,341		
Tablični χ2	**21,026**		

χ 2 < χ2 tablični 5% sign.

Prihvaća se H_0



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 4. uočljivo je kako je element telefonije i telefonskih aplikacija dobio najviše prosječne ocjene od ispitanika iz hotela na priobalju. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test potvrđuje nezavisnost ocjenjivača prema lokaciji njihova hotela.

1.26.2 Integracija fiksne i mobilne telefonije na razini hotela

Integracija fiksne i mobilne telefonije na razini hotela je drugi element ocjenjivanja koji predstavlja integraciju fiksne, mobilne i VoIP telefonije. Osim što je to dodatna povoljna usluga za goste hotela, integriranost sustava hotelu omogućuje racionalizaciju troškova s obzirom na to da integrirani sustavi koriste klasične, ali i virtualne centrale u oblaku (*cloud*) što pak omogućuje besplatne komunikacije unutar hotela i hotelskih sustava. Važna je za komunikaciju

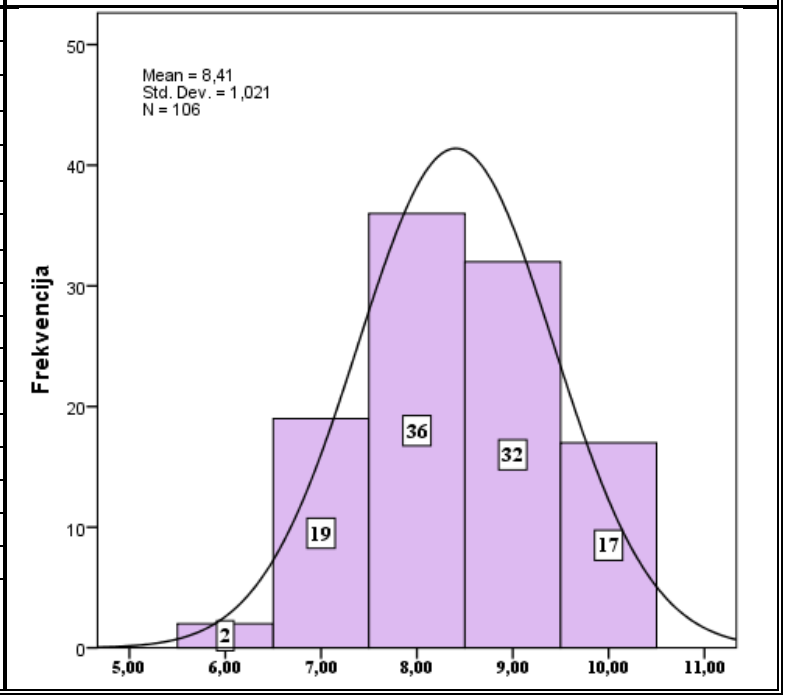
hotel – gost, gost – gost, hotel – zaposlenik, zaposlenik – zaposlenik, neovisno o tome koristi li se fiksna linja, mobiteli ili tableti za VoIP komunikaciju.

Koliko su uspješno integrirani, odgovarali su ispitanici ocjenjujući taj element.

Svi su ispitanici (100%) ocijenili taj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 5. Frekvencija i distribucija ocjena elementa integracije fiksne i mobilne telefonije na razini hotela

Integracija fiksne i mobilne telefonije		F	%
Ocjena	6	2	1,9
	7	19	17,9
	8	36	34
	9	32	30,2
	10	17	16
	Ukupno	106	100
$\bar{X}$		8,4057	
Medijan		8,0	
Mod		8,0	
SD		1,02147	
Varijanca σ^2		1,043	
Raspon		4	
Σ		891	
Skewness		-0,067	
Kurtosis		-0,717	
Percentil	25	8	
	50	8	
	75	9	



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 5. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 6 do 10. Dva su ispitanika (1,9%) dodijelila ocjenu 6 dok je 17 ispitanika (16,0%) dodijelilo maksimalnu ocjenu 10. Ocjene 9 i 8 su dominirale (ukupno 64,2%). Histogram 2. jasno predočava kako ocjene elementa integracije fiksne i mobilne telefonije na razini hotela prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je vrlo slaba i negativna -0,067 što ukazuje vrlo slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -0,717 što označava platikurtičnost koja se ogleda u umjerenom grupiranju rezultata oko aritmetičke sredine. Narednom se tablicom predočavaju rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 6. Bootstrap analiza ocjena elementa integracije fiksne i mobilne telefonije na razini hotela

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8,4057	0,0038	0,0965	8,2172	8,5849
Medijan	8	0,2130	0,3870	8,0	9,0
SD	1,02147	-0,00532	0,05560	0,90949	1,13032
Varijanca σ^2	1,043	-0,008	0,113	0,827	1,278

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element integracije fiksne i mobilne telefonije na razini hotela ocijenili prosječnom ocjenom 8,4057 uz standardnu devijaciju od 1,02147 i varijancu 1,043. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

U nastavku se analizira kako su element integracije fiksne i mobilne telefonije na razini hotela ocijenili ispitanici s obzirom na: *a) svoju poslovnu poziciju u hotelu i b) lokaciju hotela*.

c) Distribucija ocjene elementa integracije fiksne i mobilne telefonije na razini hotela prema poslovnoj poziciji ispitanika

Postavlja se istraživačka hipoteza H_I kako pozicija ispitanika utječe na dodjeljivanje ocjena elementa integracije fiksne i mobilne telefonije na razini hotela. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 7. Statistička analiza ocjena elementa integracije fiksne i mobilne telefonije na razini hotela prema poziciji ispitanika

Integracija fiksne i mobilne telefonije na razini hotela

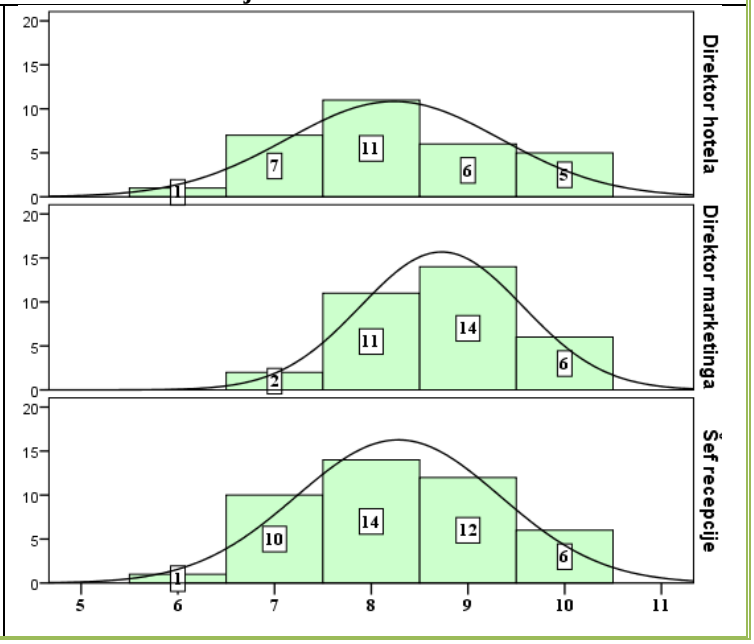
Direktor hotela	$\bar{X}$	7,73
	N	30
Direktor marketinga	$\bar{X}$	8,697
	N	33
Šef recepcije	$\bar{X}$	7,975
	N	40

N = 103

Pearson χ2	**7,816**	**df**	**8**
Omjer vjerojatnosti	9,131		8
Phi	0,272		
Cramer's V	0,192		
Koeficijent kontingencije	0,262		
Tablični χ2	15,507		

χ 2 < χ2 tablični 5% sign.

Prihvaća se H_0



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 7. uočljivo je kako je element integracije fiksne i mobilne telefonije na razini hotela dobio najviše prosječne ocjene direktora marketinga. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test potvrđuje nezavisnost ocjenjivača prema njihovoj poziciji u hotelu.

d) Distribucija ocjene elementa integracije fiksne i mobilne telefonije na razini hotela prema lokaciji hotela

Postavlja se istraživačka hipoteza H_I kako lokacija hotela ispitanika utječe na dodjeljivanje ocjena elementa integracije fiksne i mobilne telefonije na razini hotela. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 8. Statistička analiza ocjena elementa integracije fiksne i mobilne telefonije na razini hotela prema lokaciji hotela ispitanika

Integracija fiksne i mobilne telefonije na razini hotela

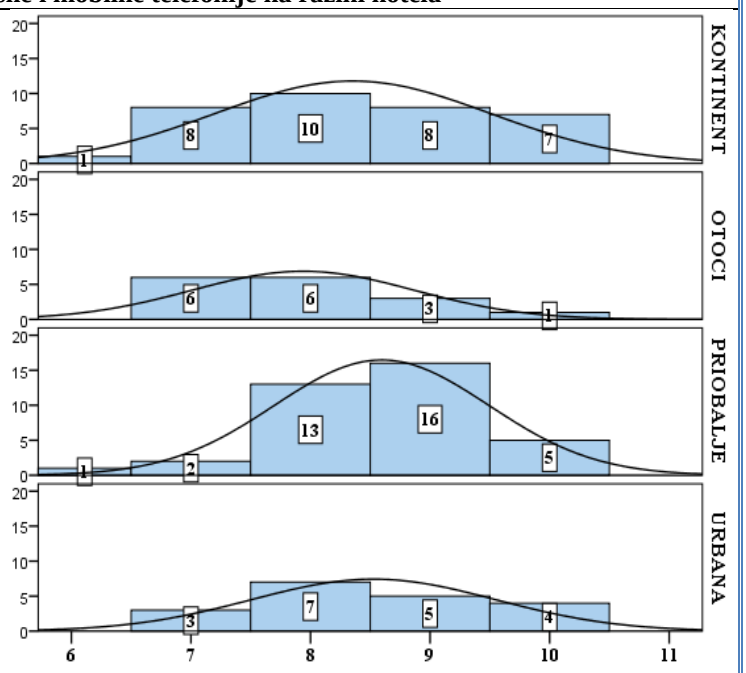
Kontinent	$\bar{X}$	8,353
	N	34
Otoci	$\bar{X}$	7,938
	N	16
Priobalje	$\bar{X}$	8,594
	N	37
Urbani	$\bar{X}$	8,526
	N	19

N = 106

Pearson χ2	**13,835**	**df**	**12**
Omjer vjerojatnosti	14,954	df	12
Phi	0,361		
Cramer's V	0,209		
Koeficijent kontingencije	0,340		
Tablični χ2	**21,026**		

χ 2 < χ2 tablični 5% sign.

Prihvaća se H_0



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 8. uočljivo je kako je element integracije fiksne i mobilne telefonije na razini hotela dobio najviše prosječne ocjene od ispitanika iz hotela na priobalju. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test potvrđuje nezavisnost ocjenjivača prema lokaciji njihova hotela.

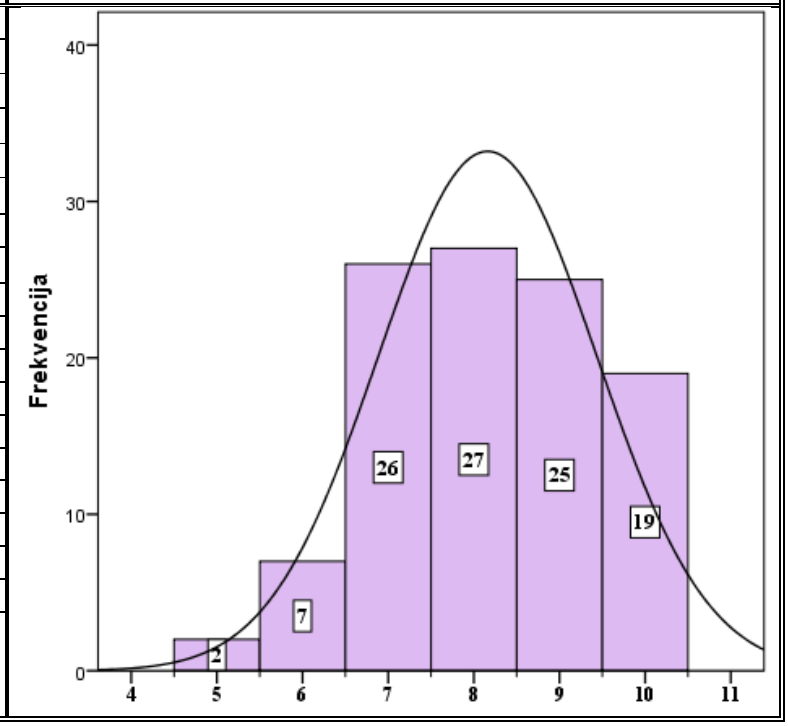
1.26.3 Hotelski sustav reklamiranja

Hotelski sustav reklamiranja čija se podloga nalazi u informatičkoj tehnologiji ima širok spektar mogućnosti kako što bolje predstaviti sve dodatne proizvode koje hotel nudi izvan osnovnog paketa (spavanje i prehrana). Primjeri su: 1) kućni TV čiji se program pokreće uključivanjem televizijskog prijamnika u sobama, 2) pametni kiosci smješteni u glavnom holu, ispred restorana i sl. na kojima se gost može informirati o dnevnim dodatnim ponudama, organiziranim izletima, sportskim priredbama, zabavama sl. 3) besplatan pristup internetu na način da se tijekom prijavljivanja na mrežu koriste reklamni baneri od važnosti za hotel. Koji i u kolikoj se mjeri koristi te kakve je kvalitete hotelski sustav reklamiranja, pitalo se ispitanike tijekom ocjenjivanja trećeg elementa, integriranih informacijsko-komunikacijskih usluga. Svi

su ispitanici (100%) ocijenili ovaj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 9. Frekvencija i distribucija ocjena elementa hotelskog sustava reklamiranja

Hotelski sustav reklamiranja		F	%
Ocjena	5	2	1,9
	6	7	6,6
	7	26	24,5
	8	27	25,5
	9	25	23,6
	10	19	17,9
	Ukupno	106	100
$\bar{X}$		8,1604	
Medijan		8,00	
Mod		8,00	
SD		1,27334	
Varijanca σ²		1,622	
Raspon		5	
Σ		865	
Skewness		-0,194	
Kurtosis		-0,465	
Percentil	25	7	
	50	8	
	75	9	



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 9. vidljivo je kako su ispitanici ocjenjivali taj element u rasponu ocjena od 5 do 10. Dva su ispitanika (1,9%) dodijelila ocjenu 5 dok je 19 ispitanika (17,9%) dodijelilo maksimalnu ocjenu 10. Ocjene 7, 8 i 9 su dominirale (ukupno 73,3%). Histogram 3. jasno predočava kako ocjene elementa hotelskog sustava reklamiranja prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,194 što ukazuje na slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -0,465 što označava platikurtičnost koja se ogleda u umjerenom grupiranju rezultata oko aritmetičke sredine. Narednom se tablicom predočavaju rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 10. Bootstrap analiza ocjena elementa hotelskog sustava reklamiranja

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8,1604	-0,0027	0,1262	7,9057	8,4245
Medijan	8	0,04	0,1842	8	9
SD	1,27344	-0,00753	0,06953	1,12926	1,40606
Varijanca σ²	1,622	-0,014	0,177	1,275	1,977

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element hotelskog sustava reklamiranja ocijenili prosječnom ocjenom 8,1604 uz standardnu devijaciju od 1,27344 i varijancu 1,622. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

U nastavku se analizira kako su element hotelskog sustava reklamiranja ocijenili ispitanici s obzirom na: *a) svoju poslovnu poziciju u hotelu i b) lokaciju hotela*.

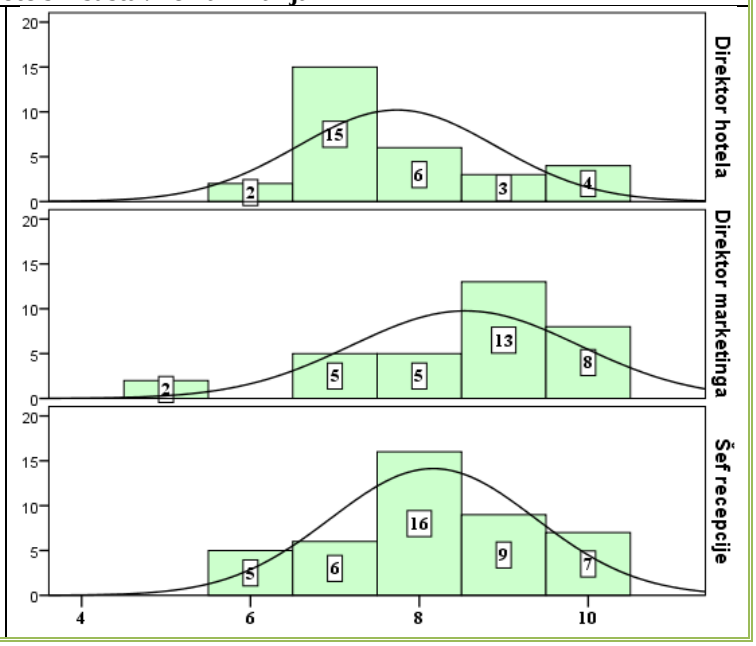
a) Distribucija ocjene elementa hotelskog sustava reklamiranja prema poslovnoj poziciji ispitanika

Postavlja se istraživačka hipoteza H_I kako pozicija ispitanika utječe na dodjeljivanje ocjena elementa hotelskog sustava reklamiranja. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 11. Statistička analiza ocjena elementa hotelskog sustava reklamiranja prema poziciji ispitanika

Hotelski sustav reklamiranja

Direktor hotela	$\bar{X}$	7,800	
	N	30	
Direktor marketinga	$\bar{X}$	8,152	
	N	33	
Šef recepcije	$\bar{X}$	7,902	
	N	41	
Pearson χ2	**30,510**	**df**	**10**
Omjer vjerojatnosti	31,330	df	10
Phi	0,563		
Cramer's V	0,379		
Koeficijent kontingencije	0,473		
Tablični χ2	18,307		
χ 2>χ2 tablični 5% sign.			
Odbacuje se H_0			



Iz tablice 11. uočljivo je kako je element hotelskog sustava reklamiranja dobio najviše prosječne ocjene od direktora marketinga. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Jaka vrijednost Cramerov V ukazuje na

izraženu asimetričnost krivulje. Hi kvadrat test potvrđuje utjecaj ocjenjivača prema njihovoj poziciji u hotelu.

b) Distribucija ocjene elementa hotelskog sustava reklamiranja prema lokaciji hotela

Postavlja se istraživačka hipoteza H_I kako lokacija hotela ispitanika utječe na dodjeljivanje ocjena elementa hotelskog sustava reklamiranja. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 12. Statistička analiza ocjena elementa hotelskog sustava reklamiranja prema lokaciji hotela ispitanika

Hotelski sustav reklamiranja

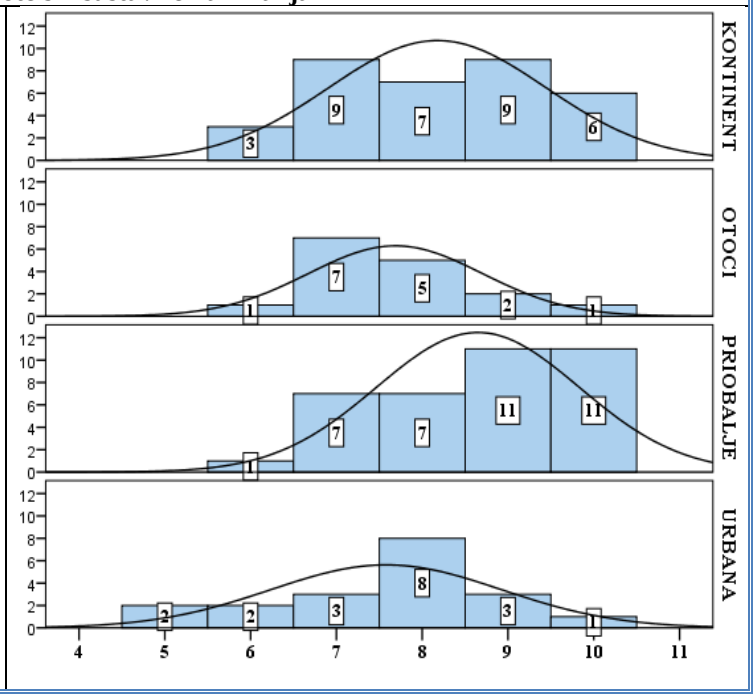
Kontinent	$\bar{X}$	8,176
	N	34
Otoci	$\bar{X}$	7,688
	N	16
Priobalje	$\bar{X}$	8,648
	N	37
Urbani	$\bar{X}$	7,578
	N	19

N = 106

Pearson χ2	**25,284**	**df**	**15**
Omjer vjerojatnosti	23,331	df	15
Phi	0,488		
Cramer's V	0,282		
Koeficijent kontingencije	0,439		
Tablični χ2	24,996		

χ 2>χ2 tablični 5% sign.

Odbacuje se H_0



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 12. uočljivo je kako je element hotelskog sustava reklamiranja dobio najviše prosječne ocjene od ispitanika iz hotela na priobalju. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test potvrđuje utjecaj ocjenjivača prema lokaciji njihova hotela čime se odbacuje nul-hipoteza o nezavisnosti varijabli i prihvaća istraživačka hipoteza H_I.

1.26.4 Zabava za goste kad su u sobama

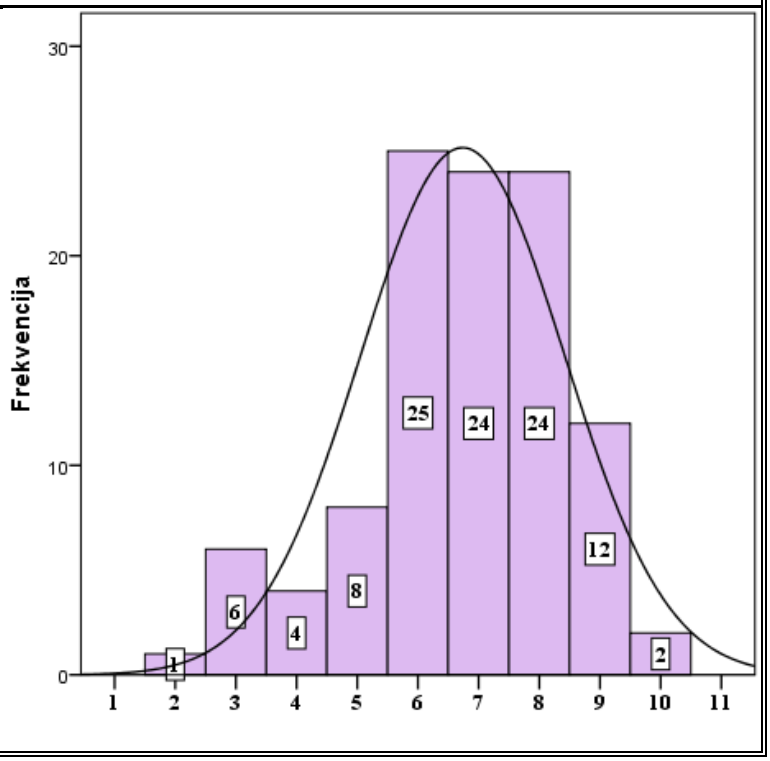
Zabava za goste kad su u sobama koja im je dostupna putem IT-a podrazumijeva *entertainment* TV, videosadržaj na zahtjev, igranje, kockanje ili druge igre na sreću, glazba po ukusu gosta i druge sadržaje. Iako je cilj svakog hotelskog menadžera da gosti što manje vremena provode u sobama, a više u restoranima i hotelskim barovima, ta je vrsta usluge sve traženija i postaje neizostavan dio hotelskog aranžmana.

Svi ispitanici (100%) ocijenili su ovaj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 13. Frekvencija i distribucija ocjena elementa zabave za goste kada su u sobama

Zabava za goste kada su u sobama		**F**	**%**
Ocjena	2	1	0,9
	3	6	5,7
	4	4	3,8
	5	8	7,5
	6	25	23,6
	7	24	22,6
	8	24	22,6
	9	12	11,3
	10	2	1,9
	Ukupno	106	100
$\bar{X}$		6,7358	
Medijan		7	
Mod		6	
SD		1,68071	
Varijanca σ^2		2,825	
Raspon		8	
Σ		714	
Skewness		-0,603	
Kurtosis		0,172	
Percentil	25	6	
	50	7	
	75	8	

Histogram ocjena elementa 4.



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 13. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 2 do 10. Jedan je ispitanik (0,9%) dodijelio ocjenu 2 dok su 2 ispitanika (1,9%) dodijelila maksimalnu ocjenu 10. Ocjene 6, 7 i 8 su dominirale (ukupno 68,8%). Histogram 4. jasno predočava kako ocjene elementa zabave za goste kada su u sobama prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,603 što ukazuje na slabi pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost

0,172 što označava umjerenu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 14. Bootstrap analiza ocjena elementa zabave za goste kada su u sobama

Statistika		Bootstrap N = 1.000			
		Bias - sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	6,7358	0,0024	0,1634	6,4151	7,0752
Medijan	7	-0,0345	0,2015	6	7
SD	1,68071	-0,00903	0,11621	1,45595	1,90621
Varijanca σ^2	2,825	-0,017	0,39	2,12	3,634

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element zabavu za goste kada su u sobama ocijenili prosječnom ocjenom 6,7358 uz standardnu devijaciju od 1,68071 i varijancu 2,825. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

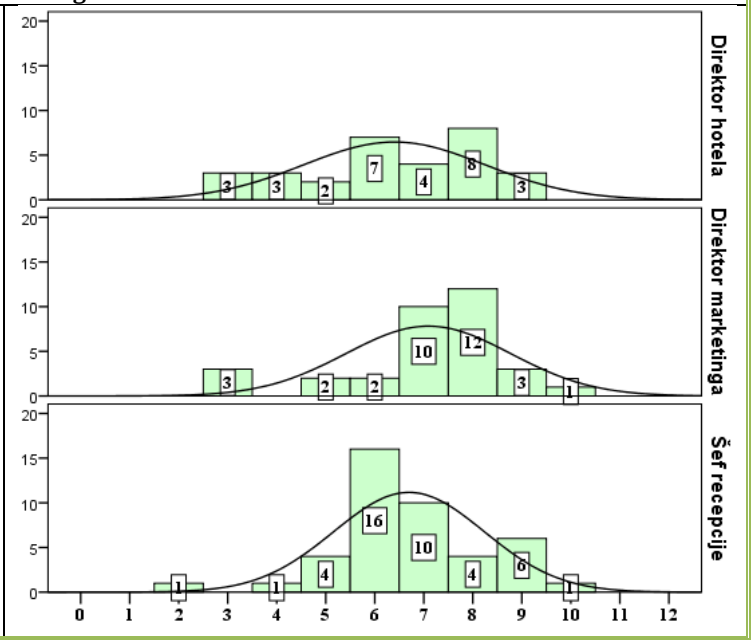
U nastavku se analizira kako su element zabavu za goste kada su u sobama ocijenili ispitanici s obzirom na: a) svoju poslovnu poziciju u hotelu i b) lokaciju hotela.

a) Distribucija ocjene elementa zabave za goste kada su u sobama prema poslovnoj poziciji ispitanika

Postavlja se istraživačka hipoteza H_I kako pozicija ispitanika utječe na dodjeljivanje ocjena elementa zabave za goste kada su u sobama. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 15. Statistička analiza ocjena elementa zabave za goste kada su u sobama prema poziciji ispitanika

Zabava za goste kada su u sobama			
Direktor hotela	$\bar{X}$	8,100	
	N	30	
Direktor marketinga	$\bar{X}$	8,575	
	N	33	
Šef recepcije	$\bar{X}$	8,023	
	N	43	
Pearson χ2	**27,777**	**df**	**16**
Omjer vjerojatnosti	33,061	df	16
Phi	0,512		
Cramer's V	0,362		
Koeficijent kontingencije	0,456		
Tablični χ2	26,296		
χ 2>χ2 tablični 5% sign.			
Odbacuje se H_0			



Iz tablice 15. uočljivo je kako je element zabave za goste kada su u sobama dobio najviše prosječne ocjene od direktora marketinga. Iz grafičkog prikaza je vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Jaka vrijednost Cramerov V ukazuje na izraženu asimetričnost krivulje. Hi kvadrat test potvrđuje utjecaj ocjenjivača prema njihovoj poziciji u hotelu.

b) Distribucija ocjene elementa zabave za goste kada su u sobama prema lokaciji hotela

Postavlja se istraživačka hipoteza H_I kako lokacija hotela ispitanika utječe na dodjeljivanje ocjena elementa zabave za goste kada su u sobama. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 16. Statistička analiza ocjena elementa zabave za goste kada su u sobama prema lokaciji hotela ispitanika

Zabava za goste kada su u sobama

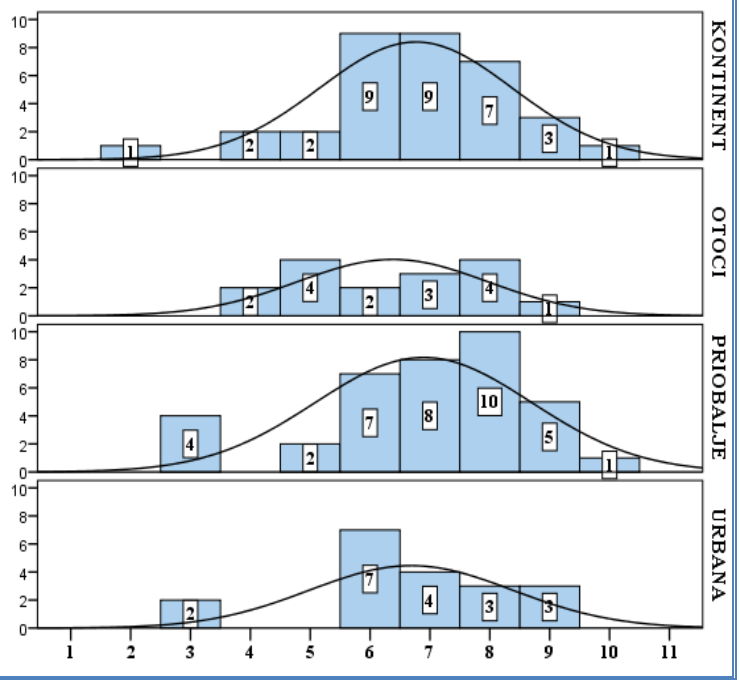
Kontinent	$\bar{X}$	6,765
	N	34
Otoci	$\bar{X}$	6,375
	N	16
Priobalje	$\bar{X}$	6,891
	N	37
Urbani	$\bar{X}$	6,684
	N	19

N = 106

Pearson χ2	**27,382**	**df**	**24**
Omjer vjerojatnosti	30,336	df	24
Phi	0,508		
Cramer's V	0,293		
Koeficijent kontingencije	0,453		
Tablični χ2	**36,415**		

χ 2 < χ2 tablični 5% sign.

Prihvaća se H₀



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 16. uočljivo je kako je element zabave za goste kada su u sobama dobio najviše prosječne ocjene od ispitanika iz hotela na priobalju. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test ne potvrđuje utjecaj ocjenjivača prema lokaciji njihova hotela čime se odbacuje istraživačka hipoteza H_I.

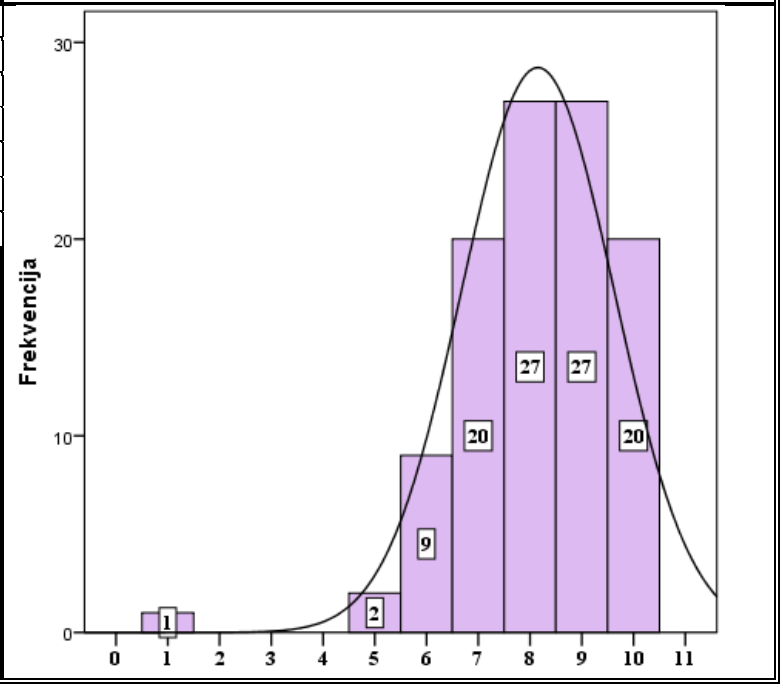
1.26.5 Pristup internetu

Dostupnost interneta (žicom ili bežično) u sobama i svim zajedničkim prostorima u hotelu smatra se "uobičajenom" ponudom većine hotela u Hrvatskoj. Druga je stvar koliko je ta usluga kvalitetna (brzina pristupa, opterećenje u pojedinim dijelovima dana, za vrijeme lošeg vremena i sl.). Većina gostiju koristi svoje pametne telefone za brz pregled vijesti i komunikaciju na društvenim mrežama o čemu ovise o dostupnosti signala svojih teleoperatera koji često nisu raspoloživi ili su usluge preskupe (primjerice gostima iz drugih kontinenata) te je njihov primaran zahtjev besplatan pristup internetu. Nadalje, poslovni ljudi rade i dok se odmaraju te

im je pristup računalu (*Internet caffe* ili *Internet corner*) sastavni dio usluge ako već nemaju svoje prijenosno računalo.

Svi su ispitanici (100%) ocijenili ovaj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 17. Frekvencija i distribucija ocjena elementa dostupnosti interneta

Dostupnost interneta		**F**	**%**	**Histogram ocjena elementa 5.**
Ocjena	1	1	0,9	
	5	2	1,9	
	6	9	8,5	
	7	20	18,9	
	8	27	25,5	
	9	27	25,5	
	10	20	18,9	
	Ukupno	106	100	
$\bar{X}$		8,1509		
Medijan		8,00		
Mod		8,00		
SD		1,47223		
Varijanca σ^2		2,167		
Raspon		9		
Σ		864		
Skewness		-1,233		
Kurtosis		3,969		
Percentil	25	7		
	50	8		
	75	9		

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 17. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 1 do 10. Jedan je ispitanik (0,9%) dodijelio ocjenu 1 dok su 20 ispitanika (18,9%) dodijelili maksimalnu ocjenu 10. Ocjene 8 i 9 su dominirale (ukupno 51%). Histogram 5. jasno predočava kako ocjene elementa dostupnosti interneta prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je izražena i negativna -1,233 što ukazuje na izražen pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 3,969 što označava izraženu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom se tablicom predočavaju rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 18. Bootstrap analiza ocjena elementa dostupnosti interneta

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8,1509	-0,0009	0,1401	7,8491	8,4057
Medijan	8	0,1115	0,3007	8	9
SD	1,47223	-0,01948	0,16265	1,18183	1,81115
Varijanca σ^2	2,167	-0,031	0,486	1,397	3,28
Skewness	-1,233	0,206	0,592	-1,956	-0,063
Kurtosis	3,969	-1,239	2,74	-0,98	6,925

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element dostupnost interneta ocijenili prosječnom ocjenom 8,1509 uz standardnu devijaciju od 1,47223 i varijancu 2,167. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su. U nastavku se analizira kako su element dostupnost interneta ocijenili ispitanici s obzirom na svoju poslovnu poziciju u hotelu te s obzirom na lokaciju hotela.

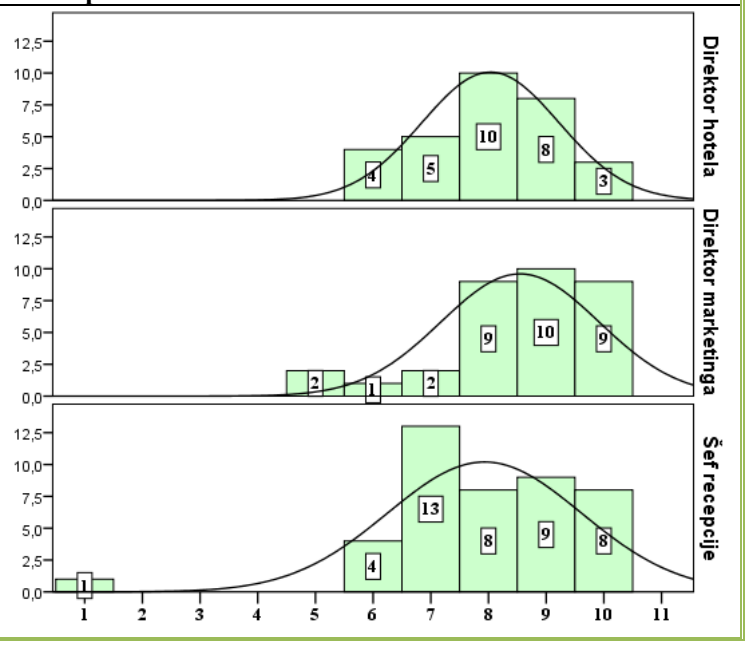
a) Distribucija ocjene elementa dostupnosti interneta prema poslovnoj poziciji ispitanika

Postavlja istraživačka hipoteza H_I kako pozicija ispitanika utječe na dodjeljivanje ocjena elementa dostupnosti interneta. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom se složenom tablicom predočavaju rezultati provedene analize.

Tablica 19. Statistička analiza ocjena elementa dostupnosti interneta prema poziciji ispitanika

Dostupnost interneta

Direktor hotela	$\bar{X}$	8,033	
	N	30	
Direktor marketinga	$\bar{X}$	8,546	
	N	33	
Šef recepcije	$\bar{X}$	7,930	
	N	43	
Pearson χ2	**18,520**	**df**	**16**
Omjer vjerojatnosti	20,080	df	12
Phi	0,418		
Cramer's V	0,296		
Koeficijent kontingencije	0,386		
Tablični χ2	21,026		
χ 2 < χ2 tablični 5% sign.			
Prihvaća se H_0			



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 19. uočljivo je kako je element dostupnost interneta dobio najviše prosječne ocjene od direktora marketinga. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na izraženu asimetričnost krivulje. Hi kvadrat test ne potvrđuje utjecaj ocjenjivača prema njihovoj poziciji u hotelu, već se kod ovog elementa prihvaća H_0 o nezavisnosti varijabli o takvom utjecaju.

b) Distribucija ocjene elementa dostupnosti interneta prema lokaciji hotela ispitanika

Postavlja se istraživačka hipoteza H_I kako lokacija hotela ispitanika utječe na dodjeljivanje ocjena elementa dostupnosti interneta. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernosti. Narednom se složenom tablicom predočavaju rezultati provedene analize.

Tablica 20. Statistička analiza ocjena elementa dostupnosti interneta prema lokaciji hotela ispitanika

Dostupnost interneta

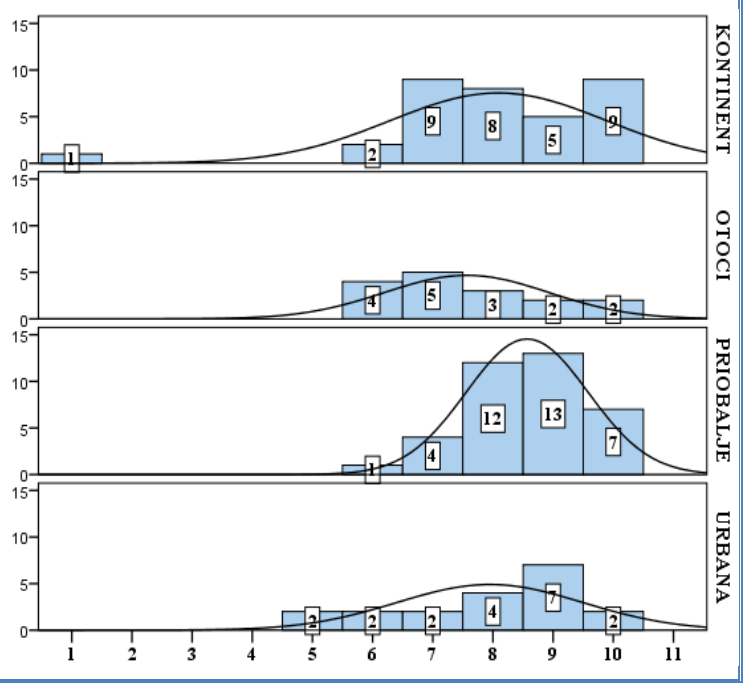
Kontinent	$\bar{X}$	8,089
	N	34
Otoci	$\bar{X}$	7,562
	N	16
Priobalje	$\bar{X}$	8,568
	N	37
Urbani	$\bar{X}$	7,947
	N	19

N = 106

Pearson χ2	**30,747**	**df**	**18**
Omjer vjerojatnosti	27,748	df	18
Phi	0,593		
Cramer's V	0,311		
Koeficijent kontingencije	0,474		
Tablični χ2	28,869		

χ 2>χ2 tablični 5% sign.

Odbacuje se H0



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 20. uočljivo je kako je element dostupnost interneta dobio najviše prosječne ocjene od ispitanika iz hotela na priobalju. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Pojačana vrijednost Cramerov V ukazuje na izraženu asimetričnost krivulje. Hi kvadrat test potvrđuje utjecaj ocjenjivača prema lokaciji njihova hotela čime se odbacuje nul-hipoteza o nezavisnosti varijabli i prihvaća istraživačka hipoteza H_I.

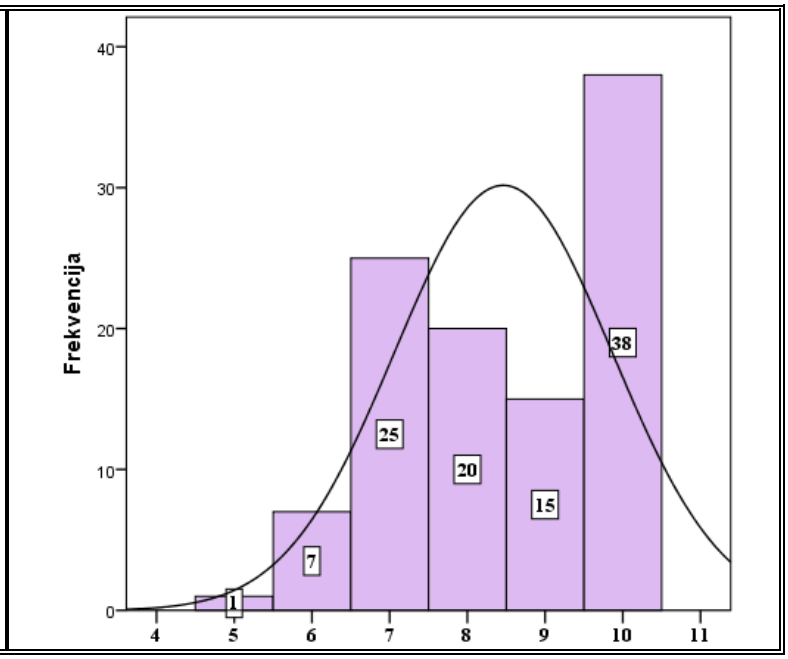
1.26.6 Kontrola ulaza

Kontrola ulaza gostiju hotela ima dvojaku funkciju. Prva je da se spriječi neovlašteno kretanje u prostorima za goste po hotelu poradi sigurnosti gostiju i osoblja, a druga je da su servisne službe upoznate kada gost nije u sobi radi nesmetanog čišćenja i servisiranja. Kontrola se uobičajeno obavlja elektroničkom karticom u kojoj su memorirani podatci o gostu i broju sobe, a koja gostu može služiti osim za otvaranje sobe i za pristup restoranu, barovima i drugim sadržajima u hotelu. Pored toga elektronička kartica (ili neki drugačije dizajniran predmet) služi i kao glavna električna sklopka kada je gost u sobi, a isključuje struju kada gost napušta sobu čime se dodatno štedi energija.

Svi su ispitanici (100%) ocijenili ovaj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 21. Frekvencija i distribucija ocjena elementa kontrole ulaza

Kontrola ulaza		**F**	**%**	**Histogram ocjena elementa 6.**
	5	1	0,9	
	6	7	6,6	
	7	25	23,6	
	8	20	18,9	
	9	15	14,2	
	10	38	35,8	
	Ukupno	106	100	
$\bar{X}$		8,4623		
Medijan		8,50		
Mod		10		
SD		1,40187		
Varijanca σ^2		1,965		
Raspon		5		
Σ		897		
Skewness		-0,302		
Kurtosis		-1,182		
Percentil	25	7		
	50	8,5		

	75	10	

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 21. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 1 do 10. Jedan je ispitanik (0,9%) dodijelio ocjenu 5 dok je 38 ispitanika (35,8%) dodijelilo maksimalnu ocjenu 10. Ocjene 7 i 8 su se isticale (ukupno 42,5%). Histogram 6. jasno predočava kako ocjene elementa kontrole ulaza ne prate normalnu razdiobu. Vidljiva je nepravilna varijabilnost koja vjerojatno proizlazi od različite veličine hotela. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,302 što ukazuje slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 0,465 što označava neznatnu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 22. Bootstrap analiza ocjena elementa kontrole ulaza

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8,4623	0,0088	0,1303	8,2078	8,7075
Medijan	8,5	0,036	0,48	8	9
SD	1,40187	-0,0086	0,06633	1,2617	1,51778
Varijanca σ^2	1,965	-0,02	0,185	1,592	2,304
Skewness	-0,302	-0,004	0,159	-0,635	0,032
Kurtosis	-1,182	0,018	0,206	-1,497	-0,698

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element kontrole ulaza ocijenili prosječnom ocjenom 8,4623 uz standardnu devijaciju od 1,40187 i varijancu 1,965. Bootstrap metoda s 95% povjerenja potvrđuje

relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

U nastavku se analizira kako su element kontrolu ulaza ocijenili ispitanici s obzirom na svoju poslovnu poziciju u hotelu te prama lokaciji na kojoj hotel posluje.

a) Distribucija ocjene elementa kontrole ulaza prema poziciji ispitanika

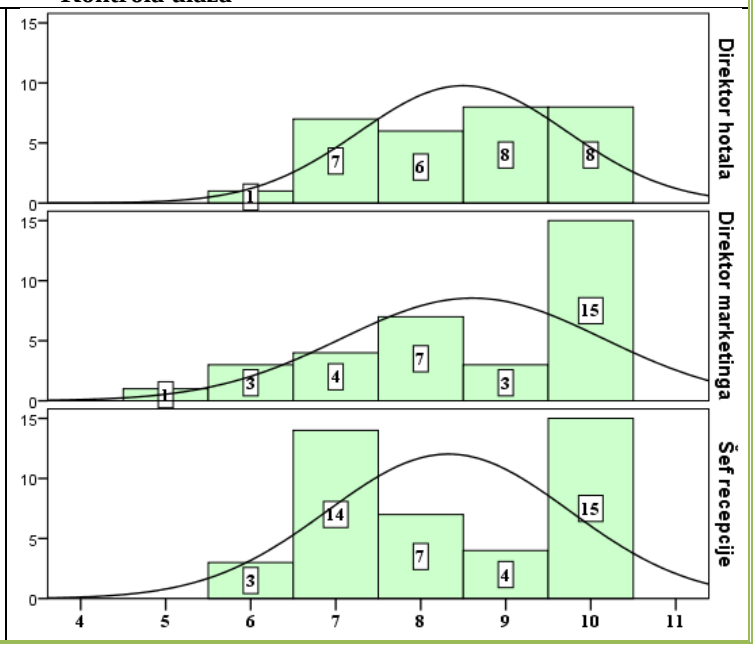
Postavlja se istraživačka hipoteza H_I kako pozicija ispitanika utječe na dodjeljivanje ocjena elementa kontrole ulaza. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 23. Statistička analiza ocjena elementa kontrole ulaza prema poziciji ispitanika

Kontrola ulaza

Direktor hotela	$\bar{X}$	8,500
	N	30
Direktor marketinga	$\bar{X}$	8,606
	N	33
Šef recepcije	$\bar{X}$	8,325
	N	43

Pearson χ2	**12,791**	**df**	**10**
Omjer vjerojatnosti	12,734	df	10
Phi	0,347		
Cramer's V	0,246		
Koeficijent kontingencije	0,328		
Tablični χ2	18,307		
χ 2 < χ2 tablični 5% sign.			
Prihvaća se H0			



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 23. uočljivo je kako je element kontrola ulaza dobio najviše prosječne ocjene od direktora marketinga. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na izraženu asimetričnost krivulje. Hi kvadrat test ne potvrđuje utjecaj ocjenjivača prema njihovoj poziciji u hotelu, već se kod ovog elementa prihvaća H_0 o nezavisnosti varijabli o takvom utjecaju.

b) Distribucija ocjene elementa kontrola ulaza prema lokaciji hotela ispitanika

Postavlja se istraživačka hipoteza H_I kako lokacija hotela ispitanika utječe na dodjeljivanje ocjena elementa kontrole ulaza. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom se složenom tablicom predočavaju rezultati provedene analize.

Tablica 24. Statistička analiza ocjena elementa kontrole ulaza prema lokaciji hotela ispitanika

Kontrola ulaza

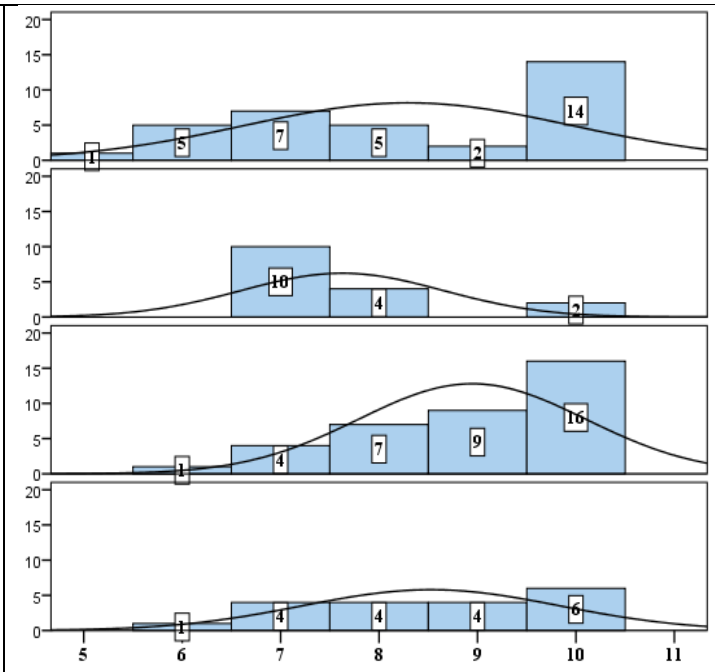
Kontinent	$\bar{X}$	8,294
	N	34
Otoci	$\bar{X}$	7,625
	N	16
Priobalje	$\bar{X}$	8,946
	N	37
Urbani	$\bar{X}$	8,526
	N	19

N = 106

Pearson χ2	**31,768**	**df**	**15**
Omjer vjerojatnosti	32,714	df	15
Phi	0547		
Cramer's V	0,316		
Koeficijent kontingencije	0,480		
Tablični χ2	24,996		

χ 2>χ2 tablični 5% sign.

Odbacuje se H_0



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 24. uočljivo je kako je element kontrola ulaza dobio najviše prosječne ocjene od ispitanika iz hotela na priobalju. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Pojačana vrijednost Cramerov V ukazuje na izraženu asimetričnost krivulje. Hi kvadrat test potvrđuje utjecaj ocjenjivača prema lokaciji

njihova hotela čime se odbacuje nul-hipoteza o nezavisnosti varijabli i prihvaća istraživačka hipoteza H_I.

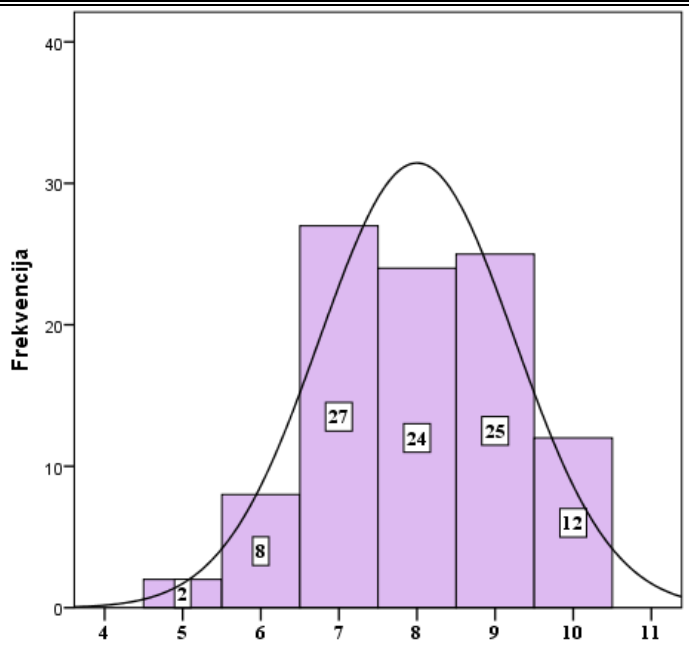
1.26.7 Kontrola i upravljanje minibarom

Kontrola i upravljanje minibarom je za hotelijere vrlo zahtjevan i problematičan ali neizostavan posao. Minibarovi su se u hotelima pojavili šezdesetih godina prošlog stoljeća i u početku su ostvarivali dodatnu dobit da bi suvremenom gostu postali nezanimljivi, a hotelima dodatno opterećenje koje zbog brenda hotela ne smiju ukloniti. Naime, problem je u tome što osoblje mora dnevno provjeravati stanje minibara i nadopunjavati ga, a često se i suočavaju s nemogućnosti naplate konzumiranih pića. Međutim na tržištu postoje mrežne i mobilne aplikacije koje su integrirane u hotelski informatički sustav i koje omogućuju upravljanje minibarom u realnom vremenu.

Od ukupno 106 ispitanika njih 98 (92,5%) dalo je svoje ocjene ovom elementu. Osam ispitanika (7,5%) nije odgovorilo na postavljeno pitanja bez obrazloženja te se može pretpostaviti kako oni u svojem hotelu nemaju tu uslugu. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 25. Frekvencija i distribucija ocjena elementa kontrole i upravljanja minibarom

Kontrola i upravljanje mini barom		**F**	**%**	**Histogram ocjena elementa 7.**
	5	2	2	
	6	8	8,2	
	7	27	27,6	
	8	24	24,5	
	9	25	25,5	
	10	12	12,2	
	Ukupno	98	100	
$\bar{X}$		8,00		
Medijan		8,00		
Mod		7,00		
SD		1,24354		
Varijanca σ^2		1,546		
Raspon		5		
Σ		784		
Skewness		-0,131		
Kurtosis		-0,646		
Percentil	25	7		
	50	8		

	75	9	

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 17. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 5 do 10. Dva su ispitanika (2,0%) dodijelila ocjenu 5 dok je 12 ispitanika (12,2%) dodijelilo maksimalnu ocjenu 10. Ocjene 7, 8 i 9 su se isticale (ukupno 77,6%). Histogram 7. jasno predočava kako ocjene elementa kontrole i upravljanja minibarom ne prate normalnu razdiobu. Vidljiva je nepravilna varijabilnost koja vjerojatno proizlazi od različite veličine hotela. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,131 što ukazuje na slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -0,646 što označava umjerenu platikurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom se tablicom predočavaju rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 26. Bootstrap analiza ocjena elementa kontrole i upravljanja minibarom

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8	0,0054	0,1297	7,7551	8,265
Medijan	8	-0,006	0,1161	8	8
SD	1,24354	-0,00928	0,07155	1,09279	1,38098
Varijanca σ^2	1,965	-0,018	0,177	1,194	1,907
Skewness	-0,131	0,004	0,168	-0,46	0,213
Kurtosis	-0,646	-0,006	0,242	-1,069	-0,106

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element kontrole i upravljanja minibarom ocijenili prosječnom ocjenom 8,00 uz standardnu devijaciju od 1,24354 i varijancu 1,965. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su. U nastavku se analizira kako su element kontrole i upravljanja minibarom ocijenili ispitanici s obzirom na svoju poslovnu poziciju u hotelu te prema lokaciji svog hotela.

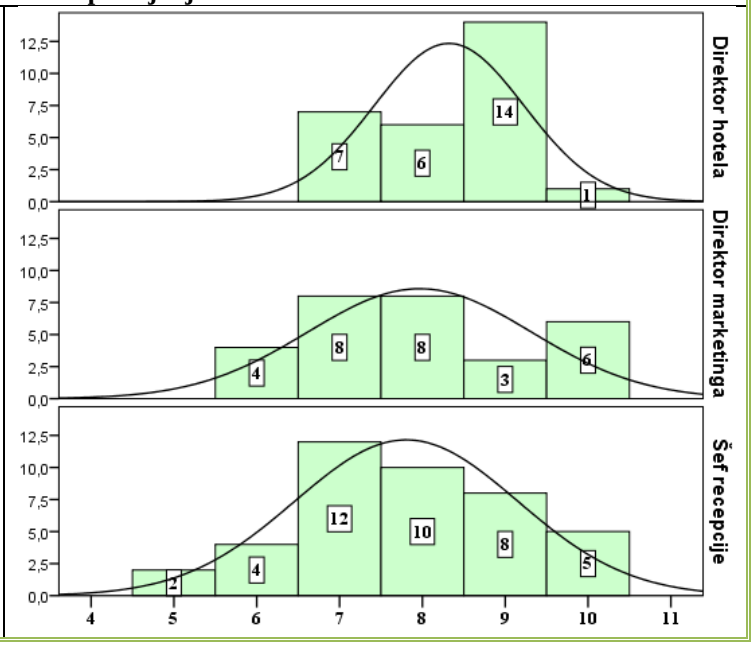
a) Distribucija ocjene elementa kontrole i upravljanja minibarom prema poziciji ispitanika

Postavlja se istraživačka hipoteza H_I kako pozicija ispitanika utječe na dodjeljivanje ocjena elementa kontrole i upravljanja minibarom. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 27. Statistička analiza ocjena elementa kontrole i upravljanja minibarom prema poziciji ispitanika

Kontrola i upravljanje minibarom

Direktor hotela	$\bar{X}$	8,321	
	N	28	
Direktor marketinga	$\bar{X}$	7,966	
	N	29	
Šef recepcije	$\bar{X}$	7,805	
	N	41	
N = 98			
Pearson χ2	**19,835**	**df**	**10**
Omjer vjerojatnosti	22,368	df	10
Phi	0,450		
Cramer's V	0,318		
Koeficijent kontingencije	0,410		
Tablični χ2	18,307		
χ 2 > χ2 tablični 5% sign.			
Odbacuje se H_0			



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 27. uočljivo je kako je element kontrola i upravljanje minibarom dobio najviše prosječne ocjene od direktora hotela. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Izražena vrijednost Cramerov V ukazuje na izraženu asimetričnost krivulje. Hi kvadrat test potvrđuje utjecaj ocjenjivača prema njihovoj poziciji u hotelu te se kod ovog elementa odbacuje H_0 o nezavisnosti varijabli i prihvaća istraživačka hipoteza o tome kako postoji zavisnost varijabli s obzirom na poziciju ispitanika.

b) Distribucija ocjene elementa kontrole i upravljanja minibarom prema lokaciji hotela ispitanika

Postavlja se istraživačka hipoteza H_I kako lokacija hotela ispitanika utječe na dodjeljivanje ocjena elementa kontrole i upravljanja minibarom. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 28. Statistička analiza ocjena elementa kontrole i upravljanja minibarom prema lokaciji hotela ispitanika

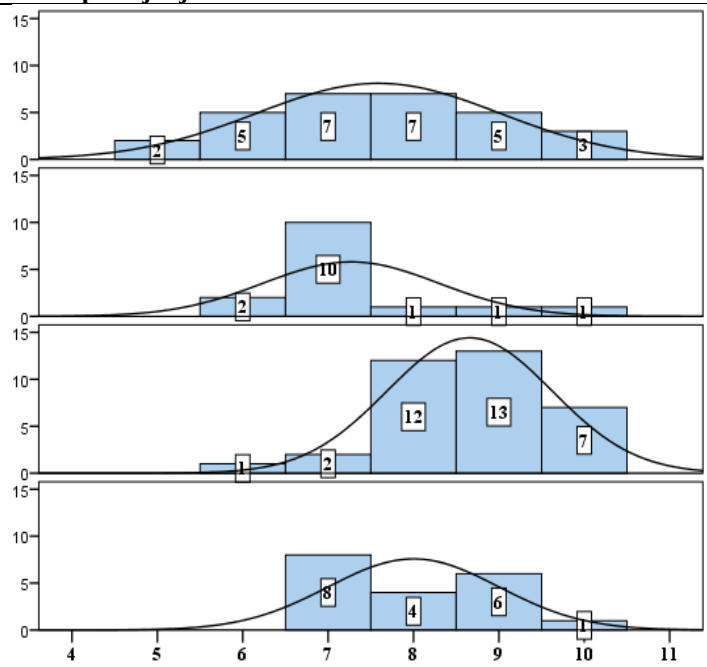
Kontrola i upravljanje minibarom

Kontinent	$\bar{X}$	7,586
	N	29
Otoci	$\bar{X}$	7,267
	N	15
Priobalje	$\bar{X}$	8,657
	N	35
Urbani	$\bar{X}$	8,00
	N	19

N = 98

Pearson χ2	**38,255**	**df**	**15**
Omjer vjerojatnosti	41,266	df	15
Phi	0,625		
Cramer's V	0,361		
Koeficijent kontingencije	0,530		
Tablični χ2	24,996		

χ 2 > χ2 tablični 5% sign.
Odbacuje se H0



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

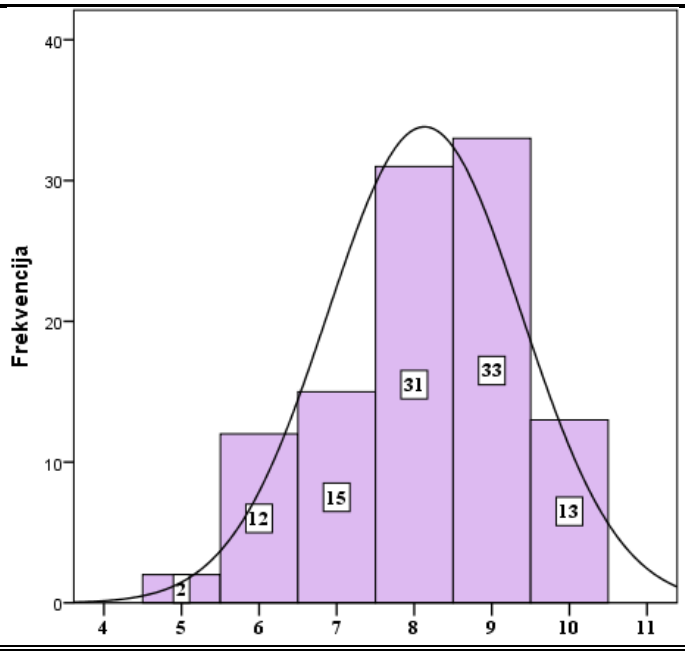
Iz tablice 28. uočljivo je kako je element kontrola i upravljanje minibarom dobio najviše prosječne ocjene od ispitanika iz hotela na priobalju. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Pojačana vrijednost Cramerov V ukazuje na izraženu asimetričnost krivulje. Hi kvadrat test potvrđuje utjecaj ocjenjivača prema lokaciji njihova hotela čime se odbacuje nul-hipoteza o nezavisnosti varijabli i prihvaća istraživačka hipoteza H_I.

1.26.8 Upravljanje osvjetljenjem

Trošak rasvjete u hotelima uvijek je važna stavka ako se ne primjenjuju sustavi za upravljanje rasvjetom. Gost koji boravi u hotelskoj sobi želi imati ambijentalnu rasvjetu sličnoj onoj koju ima u svome domu. Rasvjeta mora biti zadovoljavajuća i adekvatna prostorijama (u kupaonici jače svjetlo, u boravku umjereno, a u spavaonici diskretno). Rasvjeta u hotelima mora biti funkcionalna i ambijentalna kako u sobama, restoranima i barovima tako i okolini i pristupu hotelu. Znatne uštede postižu se korištenjem štedljivih (LED) rasvjetnih tijela i ugradnjom senzora pokreta. Svakako je najbolje elektroničko upravljanje senzorima dnevnog svjetla i isključivanjem rasvjete kada gost napušta sobu.

Svi ispitanici (100%) ocijenili su ovaj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 29. Frekvencija i distribucija ocjena elementa upravljanja osvjetljenjem

Upravljanje osvjetljenjem		F	%	Histogram ocjena elementa 8.
	5	2	1,9	
	6	12	11,3	
	7	15	14,2	
	8	31	29,2	
	9	33	31,1	
	10	13	12,3	
	Ukupno	106	100	
$\bar{X}$		8,1321		
Medijan		8,00		
Mod		9		
SD		1,25034		
Varijanca σ^2		1,563		
Raspon		5		
Σ		862		
Skewness		-0,463		
Kurtosis		-0,439		
Percentil	25	7		
	50	8		
	75	9		

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 29. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 5 do 10. Dva su ispitanika (1,9%) dodijelila ocjenu 5 dok je 13 ispitanika (12,3%) dodijelilo maksimalnu ocjenu 10. Ocjene 8 i 9 su se isticale (ukupno 60,3%). Histogram 8. jasno predočava kako ocjene elementa upravljanje osvjetljenjem prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,463 što ukazuje na slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -0,439 što označava slabu platikurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 30. Bootstrap analiza ocjena elementa upravljanja osvjetljenjem

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8,1321	0,0007	0,1206	7,8962	8,3679
Medijan	8	0,0845	0,264	8	9
SD	1,25034	-0,01271	0,07223	1,08644	1,37272
Varijanca σ^2	1,965	-0,026	0,179	1,18	1,884
Skewness	-0,463	0,006	0,156	-0,792	-0,168
Kurtosis	-0,439	0,017	0,326	-0,941	0,338

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element upravljanje osvjetljenjem ocijenili prosječnom ocjenom 8,1321 uz standardnu devijaciju od 1,25034 i varijancu 1,965. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednost Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatna je.

U nastavku se analizira kako su element upravljanje osvjetljenjem ocijenili ispitanici s obzirom na svoju poslovnu poziciju u hotelu te prema lokaciji hotela.

a) Distribucija ocjene elementa kontrole i upravljanja osvjetljenjem prema poziciji ispitanika

Postavlja se istraživačka hipoteza H_I kako pozicija ispitanika utječe na dodjeljivanje ocjena elementa upravljanje osvjetljenjem. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost.

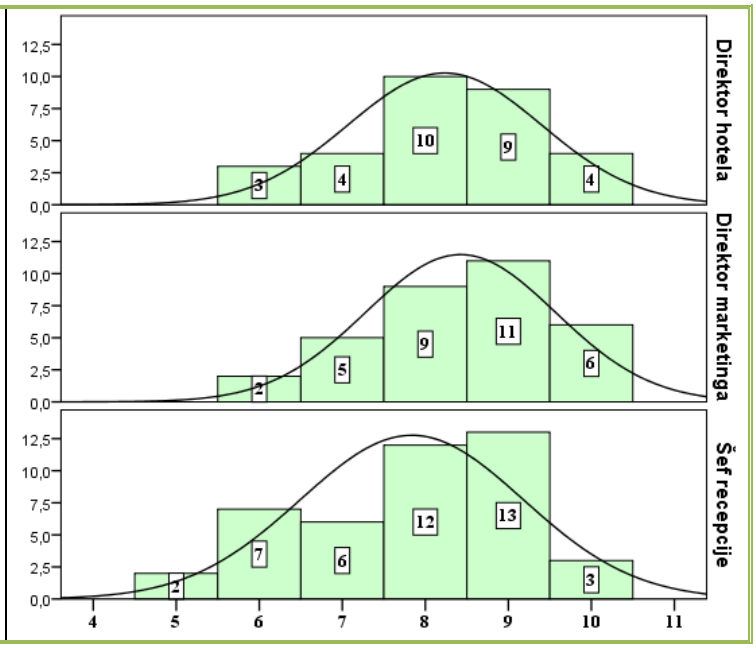
Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 31. Statistička analiza ocjena elementa upravljanje osvjetljenjem prema poziciji ispitanika

Upravljanje osvjetljenjem

Direktor hotela	$\bar{X}$	8,233	
	N	30	
Direktor marketinga	$\bar{X}$	8,424	
	N	33	
Šef recepcije	$\bar{X}$	8,132	
	N	43	
N = 106			

Pearson χ2	**7,023**	**df**	**10**
Omjer vjerojatnosti	7,808	df	10
Phi	0,257		
Cramer's V	0,182		
Koeficijent kontingencije	0,249		
Tablični χ2	18,307		
χ 2 < χ2 tablični 5% sign.			
Prihvaća se H0			



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 31. uočljivo je kako je element upravljanje osvjetljenjem dobio najviše prosječne ocjene od direktora marketinga. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Slaba vrijednost Cramerov V ukazuje na slabu asimetričnost krivulje. Hi kvadrat test ne potvrđuje utjecaj ocjenjivača prema njihovoj poziciji u hotelu, već se kod ovog elementa prihvaća H_0 o nezavisnosti varijabli o takvom utjecaju.

b) Distribucija ocjene elementa kontrole i upravljanja osvjetljenjem prema lokaciji hotela ispitanika

Postavlja se istraživačka hipoteza H_I kako lokacija hotela ispitanika utječe na dodjeljivanje ocjena elementa upravljanja osvjetljenjem. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 32. Statistička analiza ocjena elementa upravljanja osvjetljenjem prema lokaciji hotela ispitanika

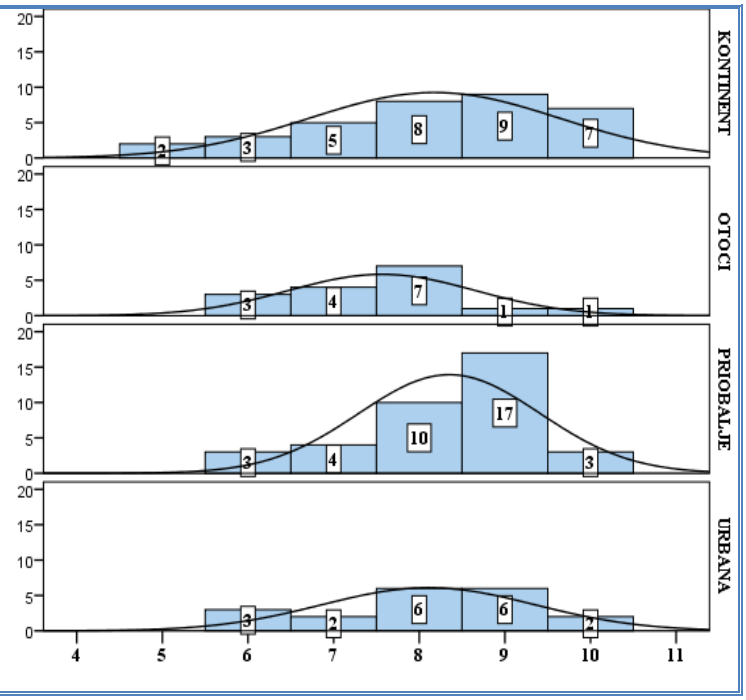
Upravljanje osvjetljenjem

Kontinent	$\bar{X}$	8,177
	N	34
Otoci	$\bar{X}$	7,563
	N	16
Priobalje	$\bar{X}$	8,351
	N	37
Urbani	$\bar{X}$	8,105
	N	19

N = 106

Pearson χ2	**18,299**	**df**	**15**
Omjer vjerojatnosti	19,261	df	15
Phi	0,415		
Cramer's V	0,240		
Koeficijent kontingencije	0,384		
Tablični χ2	**24,996**		

χ 2 < χ2 tablični 5% sign.
Prihvaća se H₀



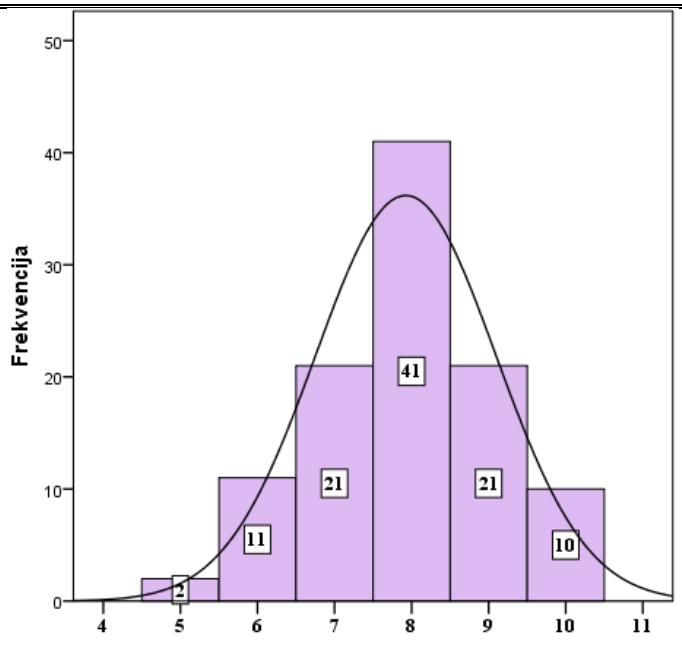
Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 32. uočljivo je kako je element upravljanje osvjetljenjem dobio najviše prosječne ocjene od ispitanika iz hotela na priobalju. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Pojačana vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test ne potvrđuje utjecaj ocjenjivača prema lokaciji njihova hotela čime se odbacuje istraživačka hipoteza H_I o utjecaju lokaliteta na ocjenjivanje elementa upravljanja osvjetljenjem čime se ujedno prihvaća nul-hipoteza o nezavisnosti varijabli.

1.26.9 Upravljanje energijom u hotelu

Upravljanje energijom u hotelskim objektima podrazumijeva kontrolu grijanja, ventilacije, rashladnog sustava i tople vode. Svijest o potrebi gospodarenja energijom, odnosno potrebi primjene mjera energetske učinkovitosti u hotelima, prisutna je i u hotelijera i u gostiju, koji sve više razumiju potrebu za nerasipanjem energije. Integrirani sustavi pametnih hotela upravljaju potrošnjom energije pa se primjerice otvaranjem prozora u sobama automatski isključuju šuštavi za hlađenje ili grijanje sobe, voda se zagrijava na 45 °C, po izlasku gostiju iz sobe temperatura se podešava na sobnu temperaturu. Svi su ispitanici (100%) ocijenili ovaj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 33. Frekvencija i distribucija ocjena elementa upravljanja energijom

Upravljanje energijom		F	%	Histogram ocjena elementa 9.
	5	2	1,9	
	6	11	10,4	
	7	21	19,8	
	8	41	38,7	
	9	21	19,8	
	10	10	9,4	
	Ukupno	106	100	
$\bar{X}$		7,9245		
Medijan		8,00		
Mod		8,00		
SD		1,16862		
Varijanca σ²		1,366		
Raspon		5		
Σ		840		
Skewness		-0,179		
Kurtosis		-0,465		
Percentil	25	7		
	50	8		
	75	9		

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 33. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 5 do 10. Dva su ispitanika (1,9%) dodijelila ocjenu 5 dok je 10 ispitanika (9,4%) dodijelilo maksimalnu ocjenu 10. Ocjena 8 je istaknuta (38,7%). Histogram 9. jasno predočava kako ocjene elementa upravljanje energijom prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,179 što ukazuje na vrlo slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -0,465 što označava slabu platikurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 34. Bootstrap analiza ocjena elementa upravljanja energijom

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	7,9245	0,0046	0,1152	7,6981	8,1604
Medijan	8	0	0	8	8
SD	1,16862	-0,01123	0,07728	1,00404	1,30478
Varijanca σ²	1,366	-0,02	0,179	1,008	1,702
Skewness	-0,179	0,008	0,162	-0,495	0,152
Kurtosis	-0,243	0,008	0,301	-0,741	0,449

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element upravljanja osvjetljenjem ocijenili prosječnom ocjenom 7,9245 uz standardnu devijaciju od 1,16862 i varijancu 1,366. Bootstrap metoda s 95% povjerenja

potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

U nastavku se analizira kako su element upravljanje energijom ocijenili ispitanici s obzirom na svoju poslovnu poziciju u hotelu te prema lokaciji hotela.

a) Distribucija ocjene elementa kontrole i upravljanja energijom prema poziciji ispitanika

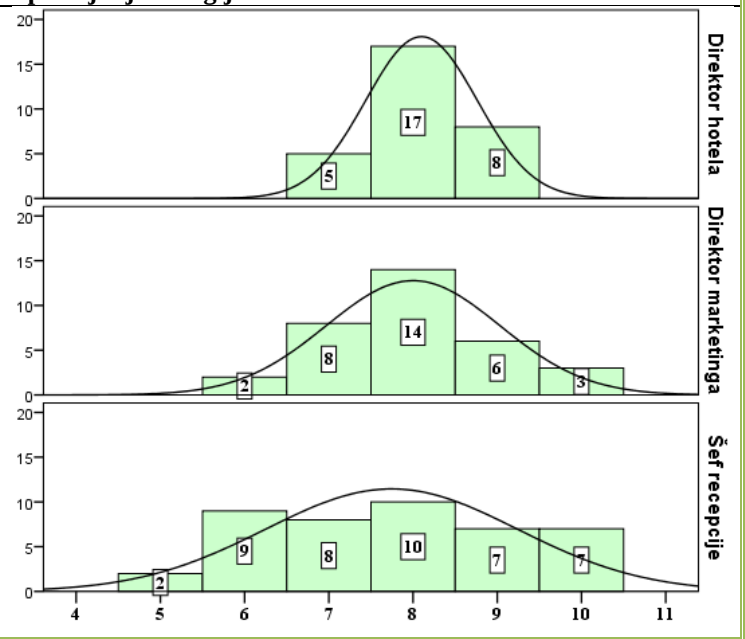
Postavlja se istraživačka hipoteza H_I kako pozicija ispitanika utječe na dodjeljivanje ocjena elementa upravljanja energijom. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 35. Statistička analiza ocjena elementa upravljanja energijom prema poziciji ispitanika

Upravljanje energijom

Direktor hotela	$\bar{X}$	8,100	
	N	30	
Direktor marketinga	$\bar{X}$	8,00	
	N	33	
Šef recepcije	$\bar{X}$	7,744	
	N	43	
N = 106			

Pearson χ2	23,029	**df**	**10**
Omjer vjerojatnosti	28,369	df	10
Phi	0,466		
Cramer's V	0,330		
Koeficijent kontingencije	0,422		
Tablični χ2	18,307		
χ 2 > χ2 tablični 5% sign.			
Odbacuje se H0			



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 35. uočljivo je kako je element upravljanja energijom dobio najviše prosječne ocjene od direktora hotela. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test potvrđuje utjecaj ocjenjivača prema njihovoj poziciji u hotelu te se kod ovog elementa odbacuje H_0 o nezavisnost varijabli i prihvaća istraživačka hipoteza o tome kako postoji zavisnost varijabli s obzirom na poziciju ispitanika.

b) Distribucija ocjene elementa kontrole i upravljanja energijom prema lokaciji hotela ispitanika

Postavlja se istraživačka hipoteza H_I kako lokacija hotela ispitanika utječe na dodjeljivanje ocjena elementa upravljanja energijom. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 36. Statistička analiza ocjena elementa upravljanja energijom prema lokaciji hotela ispitanika

Upravljanje energijom

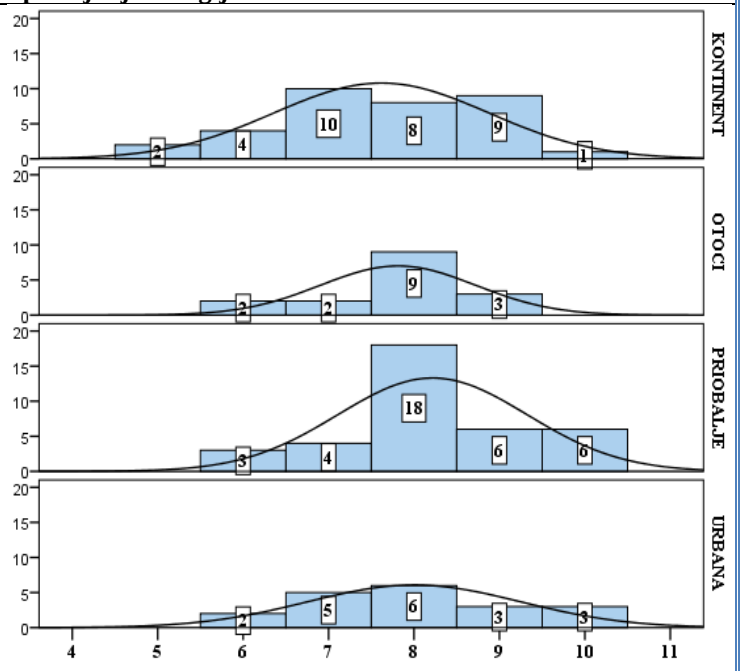
Kontinent	$\bar{X}$	7,618
	N	34
Otoci	$\bar{X}$	7,813
	N	16
Priobalje	$\bar{X}$	8,216
	N	37
Urbani	$\bar{X}$	8,00
	N	19

N = 106

Pearson χ2	**19,790**	**df**	**15**
Omjer vjerojatnosti	21,918	df	15
Phi	0,432		
Cramer's V	0,249		
Koeficijent kontingencije	0,397		
Tablični χ2	**24,996**		

χ 2 < χ2 tablični 5% sign.

Prihvaća se H0



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

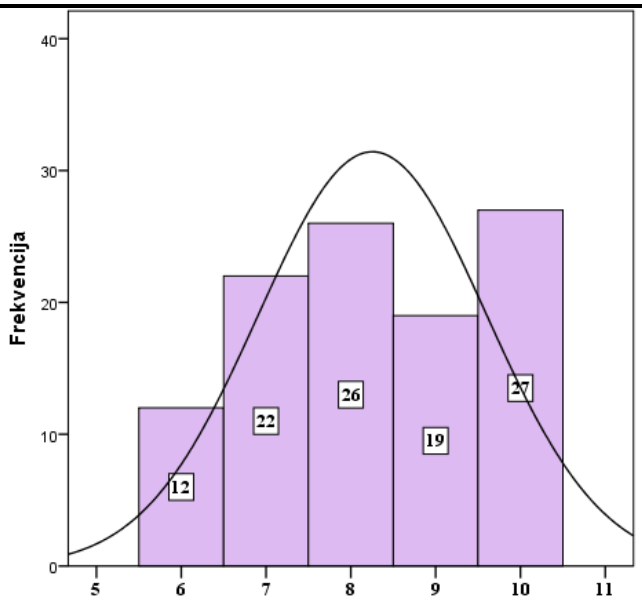
Iz tablice 36. uočljivo je kako je element upravljanje energijom dobio najviše prosječne ocjene od ispitanika iz hotela na priobalju. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Pojačana vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test ne potvrđuje utjecaj ocjenjivača prema lokaciji njihova hotela čime se odbacuje istraživačka hipoteza H_I o utjecaju lokaliteta na ocjenjivanje elementa upravljanja energijom' čime se ujedno prihvaća nul-hipoteza o nezavisnosti varijabli.

1.26.10Upravljanje sigurnošću u hotelu

Upravljanje sigurnošću u hotelima s aspekta integriranog informatičkog sustava podrazumijeva sustav vatrodojave, sustav gašenja (*sprinkler*), poziv za pomoć, videonadzor i evakuacijska rasvjeta. S obzirom na to da se radi o sustavima tehničke zaštite to je i njihovo integriranje u sustav „pametnog hotela“ praktično izvodljivo.

Svi su ispitanici (100%) ocijenili ovaj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 37. Frekvencija i distribucija ocjena elementa upravljanja sigurnošću

Upravljanje sigurnošću		F	%	Histogram ocjena elementa 10.
	6	12	11,3	
	7	22	20,8	
	8	26	24,5	
	9	19	17,9	
	10	27	25,5	
	Ukupno	106	100	
$\bar{X}$		8,2547		
Medijan		8,00		
Mod		10		
SD		1,34562		
Varijanca σ^2		1,811		
Raspon		4		
Σ		875		
Skewness		-0,120		
Kurtosis		-1,177		
Percentil	25	7		
	50	8		
	75	10		

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 37. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 6 do 10. Dvanaest je ispitanika (11,3%) dodijelio ocjenu 6 dok je 27 ispitanika (25,5%) dodijelilo maksimalnu ocjenu 10. Suženi rang ocjena ukazuje na usklađen pristup problematici upravljanja sigurnošću u hotelima. Histogram 10. predočava kako ocjene elementa upravljanje sigurnošću ne prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,120 što ukazuje na vrlo slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -1,177 što označava umjerenu platikurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom se tablicom predočavaju rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 38. Bootstrap analiza ocjena elementa upravljanja sigurnošću

Statistika	Bootstrap N = 1.000

		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8,2547	0,0074	0,1278	8,0094	8,5094
Medijan	8	0,0835	0,2614	8	9
SD	1,34562	-0,00631	0,06072	1,21198	1,45516
Varijanca σ^2	1,811	-0,013	0,162	1,469	2,118
Skewness	-0,12	-0,002	0,136	-0,387	0,144
Kurtosis	-1,177	0,025	0,128	-1,374	-0,865

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

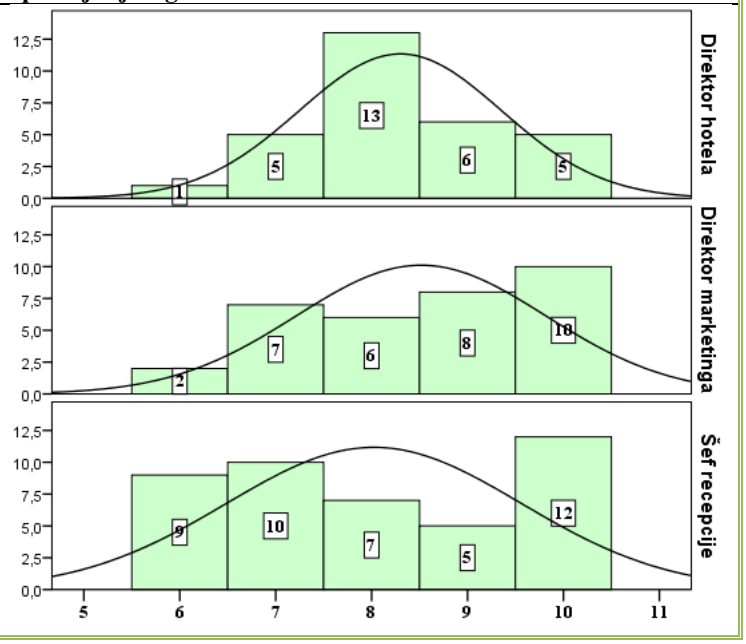
Ispitanici su element upravljanja sigurnošću ocijenili prosječnom ocjenom 8,2547 uz standardnu devijaciju od 1,34562 i varijancu 1,811. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su. U nastavku se analizira kako su element upravljanje sigurnošću ocijenili ispitanici s obzirom na svoju poslovnu poziciju u hotelu te prema lokaciji ispitanikova hotela.

a) Distribucija ocjene elementa upravljanja sigurnošću prema poziciji ispitanika

Postavlja se istraživačka hipoteza H_I kako pozicija ispitanika utječe na dodjeljivanje ocjena elementa upravljanja sigurnošću. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom se složenom tablicom predočavaju rezultati provedene analize.

Tablica 39. Statistička analiza ocjena elementa upravljanje sigurnošću prema poziciji ispitanika

Upravljanje sigurnošću			
Direktor hotela	$\bar{X}$	8,300	
	N	30	
Direktor marketinga	$\bar{X}$	8,515	
	N	33	
Šef recepcije	$\bar{X}$	8,023	
	N	43	
N = 106			
Pearson χ2	**15,513**	**df**	**8**
Omjer vjerojatnosti	15,210	df	8
Phi	0,383		
Cramer's V	0,271		
Koeficijent kontingencije	0,357		
Tablični χ2	15,507		
χ 2 > χ2 tablični 5% sign.			
Odbacuje se H_0			



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 39. uočljivo je kako je element upravljanje sigurnošću dobio najviše prosječne ocjene od direktora marketinga. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija

ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test potvrđuje utjecaj ocjenjivača prema njihovoj poziciji u hotelu te se kod ovog elementa odbacuje H_0 o nezavisnosti varijabli i prihvaća istraživačka hipoteza o tome kako postoji zavisnost varijabli s obzirom na poziciju ispitanika.

b) Distribucija ocjene elementa upravljanje sigurnošću prema lokaciji hotela ispitanika

Postavlja se istraživačka hipoteza H_I kako lokacija hotela ispitanika utječe na dodjeljivanje ocjena elementa upravljanja sigurnošću. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 40. Statistička analiza ocjena elementa upravljanja sigurnošću prema lokaciji hotela ispitanika

Upravljanje sigurnošću hotela

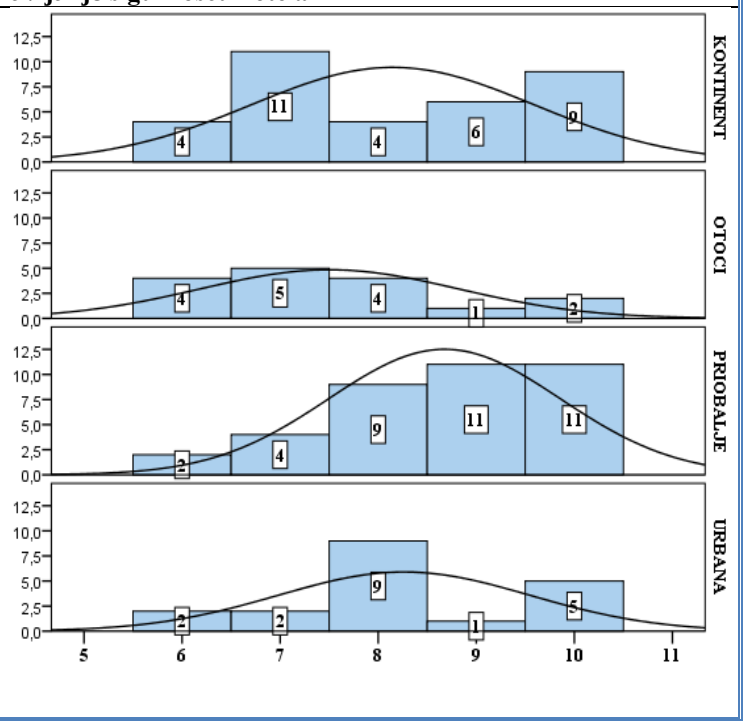
Kontinent	$\bar{X}$	8,147
	N	34
Otoci	$\bar{X}$	7,500
	N	16
Priobalje	$\bar{X}$	8,676
	N	37
Urbani	$\bar{X}$	8,263
	N	19

N = 106

Pearson χ2	**23,012**	**df**	**12**
Omjer vjerojatnosti	23,252	df	12
Phi	0,466		
Cramer's V	0,269		
Koeficijent kontingencije	0,422		
Tablični χ2	21,026		

χ 2 > χ2 tablični 5% sign.

Odbacuje se H_0



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 40. uočljivo je kako je element upravljanje sigurnošću hotela dobio najviše prosječne ocjene od ispitanika iz hotela na priobalju. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test potvrđuje utjecaj ocjenjivača prema

lokaciji njihova hotela čime se prihvaća istraživačka hipoteza H_I o utjecaju lokaliteta na ocjenjivanje elementa upravljanje sigurnošću hotela čime se ujedno odbacuje nul-hipoteza o nezavisnosti varijabli.

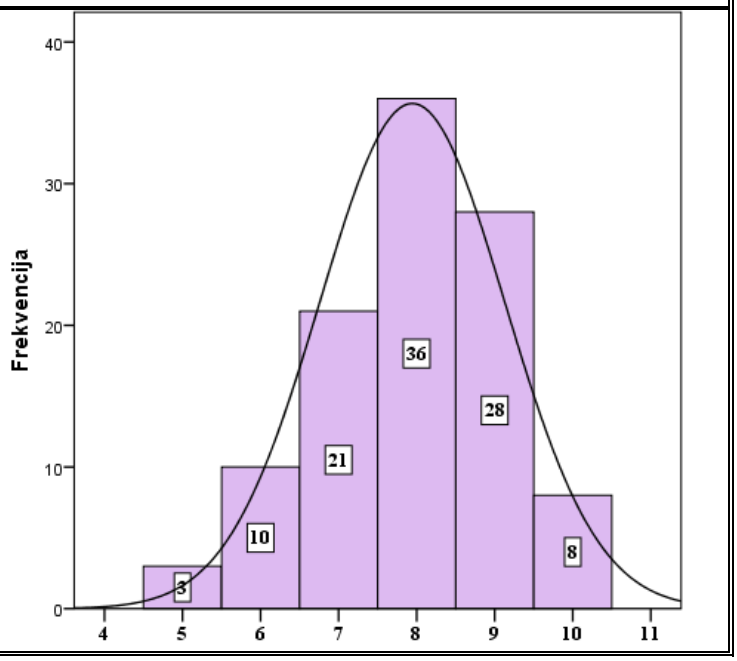
1.26.11Korištenje pametnih kartica

Integriranost u sustav informatičkog upravljanja hotelom izvediva je tehnički korištenjem pametnih kartica (engl. *Smart Card Billing*) koje gosti zadužuju na recepciji prilikom prijave i koja bilježi sva kretanja i za hotel važne radnje gosta do njegove odjave iz hotela. Kartica olakšava gostu pristup svim sadržajima hotela, služi kao ključ sobe, prolaz za dodatne sadržaje (bazen, sauna, golf ili tenisko igralište…). Za pretpostaviti je da će razvojem mobilne tehnologije i uvođenjem 5G sustava pametne kartice zamijeniti QR kodovi koji će se očitavati mobitelom (već ih primjenjuju neki veliki svjetski hotelski lanci).

Svi su ispitanici (100%) ocijenili ovaj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 41. Frekvencija i distribucija ocjena elementa pametnih kartica

Pametne kartice		F	%	Histogram ocjena elementa 11.
	5	3	2,8	
	6	10	9,4	
	7	21	19,8	
	8	36	34	
	9	28	26,4	
	10	8	7,5	
	Ukupno	106	100	
$\bar{X}$		7,9434		
Medijan		8,00		
Mod		8		
SD		1,18587		
Varijanca σ^2		1,406		
Raspon		5		
Σ		842		
Skewness		-0,378		
Kurtosis		0,465		
Percentil	25	7		
	50	8		
	75	9		



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 41. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 5 do 10. Tri su ispitanika (2,8%) dodijelila ocjenu 5 dok je 8 ispitanika (7,5%) dodijelilo maksimalnu

ocjenu 10. Histogram 11. predočava kako ocjene elementa integriranosti pametnih kartica prate normalnu razdiobu. Uočljiva je koncentracija oko ocjene 8, koju je dalo 34% ispitanika. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,378 što ukazuje na slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 0,465 što označava umjerenu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 42. Bootstrap analiza ocjena elementa pametnih kartica

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	7,9434	0,0014	0,1087	7,7267	8,1604
Medijan	8	0	0	8	8
SD	1,18587	-0,00502	0,07308	1,02813	1,32361
Varijanca σ^2	1,406	-0,007	0,172	1,057	1,752
Skewness	-0,378	0,005	0,172	-0,708	-0,03
Kurtosis	-0,22	-0,009	0,309	-0,787	0,468

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element integriranosti pametnih kartica ocijenili prosječnom ocjenom 7,9434 uz standardnu devijaciju od 1,18587 i varijancu 1,406. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

U nastavku se analizira kako su element integriranosti pametnih kartica ocijenili ispitanici s obzirom na svoju poslovnu poziciju u hotelu te prema lokaciji ispitanikova hotela.

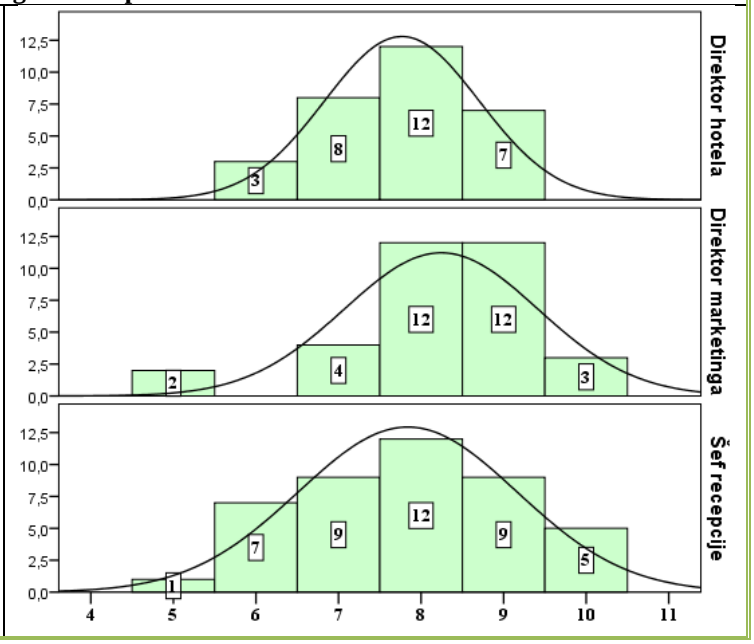
a) Distribucija ocjene elementa integriranosti pametnih kartica prema poziciji ispitanika

Postavlja se istraživačka hipoteza H_I kako pozicija ispitanika utječe na dodjeljivanje ocjena elementa integriranosti pametnih kartica. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 43. Statistička analiza ocjena elementa integriranosti pametnih kartica prema poziciji ispitanika

Integriranost pametnih kartica

Direktor hotela	$\bar{X}$	7,767	
	N	30	
Direktor marketinga	$\bar{X}$	8,242	
	N	33	
Šef recepcije	$\bar{X}$	7,834	
	N	43	
N = 106			
Pearson χ2	**15,081**	**df**	**10**
Omjer vjerojatnosti	20,492	df	10
Phi	0,377		
Cramer's V	0,267		
Koeficijent kontingencije	0,353		
Tablični χ2	18,307		
χ 2 < χ2 tablični 5% sign.			
Prihvaća se H0			



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 43. uočljivo je kako je element integriranosti pametnih kartica dobio najviše prosječne ocjene od direktora marketinga. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test ne potvrđuje utjecaj ocjenjivača prema njihovoj poziciji u hotelu te se kod ovog elementa prihvaća H_0 o nezavisnosti varijabli i odbacuje istraživačka hipoteza o tome kako postoji zavisnost varijabli s obzirom na poziciju ispitanika.

b) Distribucija ocjene elementa integriranost pametnih kartica prema lokaciji hotela ispitanika

Postavlja se istraživačka hipoteza H_1 kako lokacija hotela ispitanika utječe na dodjeljivanje ocjena elementa integriranosti pametnih kartica. Nasuprot tome postavljena je nul-hipoteza H_0 koja ukazuje na nezavisnost varijabli, odnosno ravnomjernost. Narednom složenom tablicom predočavaju se rezultati provedene analize.

Tablica 44. Statistička analiza ocjena elementa integriranosti pametnih kartica prema lokaciji hotela ispitanika

Integriranost pametnih kartica

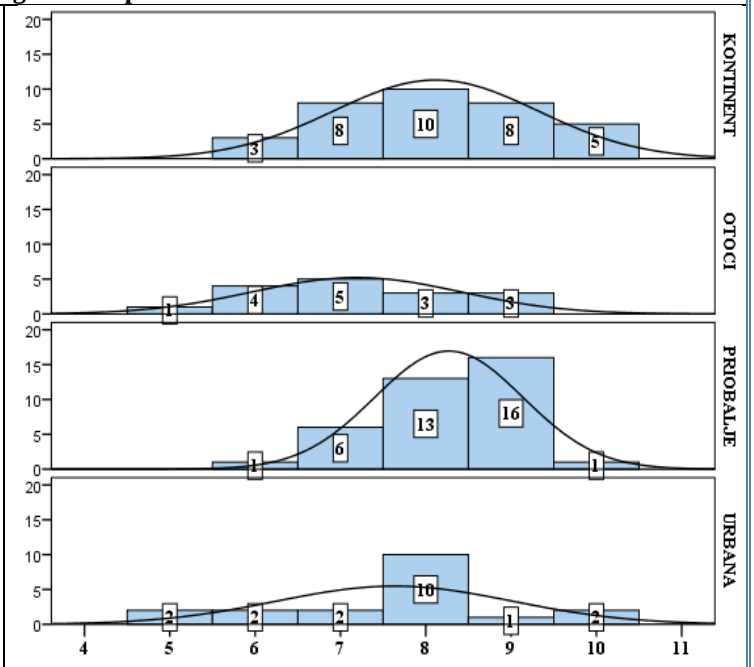
Kontinent	$\bar{X}$	8,147
	N	34
Otoci	$\bar{X}$	7,500
	N	16
Priobalje	$\bar{X}$	8,676
	N	37
Urbani	$\bar{X}$	8,263
	N	19

N = 106

Pearson χ2	**23,012**	**df**	**12**
Omjer vjerojatnosti	23,252	df	12
Phi	0,466		
Cramer's V	0,269		
Koeficijent kontingencije	0,422		
Tablični χ2	21,026		

χ 2 > χ2 tablični 5% sign.

Odbacuje se H_0



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz tablice 44. uočljivo je kako je element integriranosti pametnih kartica dobio najviše prosječne ocjene od ispitanika iz hotela na priobalju. Iz grafičkog je prikaza vidljivo kako se frekvencija i distribucija ocjena odnose prema normalnoj razdiobi. Umjerena vrijednost Cramerov V ukazuje na umjerenu asimetričnost krivulje. Hi kvadrat test potvrđuje utjecaj ocjenjivača prema lokaciji njihova hotela čime se prihvaća istraživačka hipoteza H_I o utjecaju lokaliteta na ocjenjivanje elementa upravljanja sigurnošću hotela čime se ujedno odbacuje nul-hipoteza o nezavisnosti varijabli.

1.26.12Analiza osnovnih usluga integriranih informacijsko-komunikacijskih usluga

Osnovne usluge koje su kao elementi integriranih komunikacijskih usluga prethodno analizirane, pojedinačno i sa stajališta pozicije ispitanika u hotelu te lokacije hotela kao indikativni pokazatelji moguće različitosti promišljanja ispitanika ukazali su kako ne postoje bitne razlike u dodjeljivanju ocjena. Raspon ocjena ukazuje na širinu ocjenjivanja, a prosječne ocjene su iznad 8 što ukazuje na visoku razinu razumijevanja problematike korištenja CRM-a u hotelima. Najbolje ocjene dodjeljivali su direktori marketinga u hotelima u priobalju.

Testiranjem hipoteza istraživanja za svaki pojedini element u većini slučajeva su pokazali kako postoji utjecaj osobnosti na razdiobu ocjena što je i razumljivo kako i pozicije ispitanika u hotelu tako i lokaliteta na kojem djeluje.

U nastavku se metodom analize varijance analiziraju osnovni elementi integriranih komunikacijskih usluga u hotelu (objedinjeni 1-11) s aspekta: a) starosne dobi ispitanika i b) namjene hotela.

a) Distribucija ocjene osnovnih usluga prema starosnoj dobi ispitanika

Starosna je dob ispitanika nezaobilazan atribut svakog istraživanja s obzirom na to da je prirodno da osoba sa svojim starenjem i iskustvom profilira svoje mišljenje i stavove o određenoj problematici. Stereotip je da razlika u godinama percipira oprečne stavove kada su u pitanju nove tehnologije i inovacije što je i predmet istraživanja.

Prosječne ocjene koje su izračunate na temelju podataka iz anketnog upitnika za svaku od osnovnih usluga – OU razvrstane su prema dobnim skupinama ispitanika te se predočavaju narednom tablicom.

Tablica 45. Prosječne ocjene osnovnih usluga prema dobi ispitanika

DOB		OU1	OU2	OU3	OU4	OU5	OU6	OU7	OU8	OU9	OU10	OU11
- 35	$\bar{X}$	8,65	8,35	8,29	6,06	8,06	8,82	8,07	8,47	8,47	8,82	8,24
	N	17	17	17	17	17	17	15	17	17	17	17
	SD	0,93	1,00	1,31	2,16	2,08	1,24	1,10	1,01	1,01	1,19	1,30
36-45	$\bar{X}$	8,62	8,62	8,54	7,23	8,62	8,69	8,06	8,36	8,10	8,54	8,33
	N	39	39	39	39	39	39	36	39	39	39	39
	SD	1,07	0,99	1,10	1,42	1,27	1,45	1,33	1,22	0,99	1,33	0,93
46-55	$\bar{X}$	8,71	8,41	8,09	6,88	8,15	8,47	8,00	7,91	7,47	7,91	7,68
	N	34	34	34	34	34	34	33	34	34	34	34
	SD	1,06	0,99	1,11	1,47	1,18	1,28	1,41	1,40	1,28	1,26	1,04
56+	$\bar{X}$	8,19	7,94	7,25	5,94	7,13	7,50	7,79	7,69	7,88	7,69	7,25
	N	16	16	16	16	16	16	14	16	16	16	16
	SD	0,91	1,12	1,57	1,73	1,31	1,37	0,70	1,08	1,20	1,40	1,53

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Istaknute su najveće prosječne ocjene OU s obzirom na dob ispitanika, slijedi analiza varijanci:

Tablica 46. Analiza varijance osnovnih usluga prema starosnoj dobi ispitanika

ANOVA		Zbroj kvadrata	df	Srednji kvadrati	F	F granični za 5% sign.
Telefonija i telefonske aplikacije * dob ispitanika	Između grupa	3,126	3	1,042	0,997	3;102
	Unutar grupe	106,609	102	1,045		**2,70**
	Ukupno	109,736	105			
Integracija fiksne i mobilne telefonije * dob ispitanika	Između grupa	5,271	3	1,757	1,718	3;102
	Unutar grupe	104,286	102	1,022		**2,70**
	Ukupno	109,557	105			
Hotelski sustav reklamiranja * dob ispitanika	Između grupa	19,317	3	6,439	4,351	3;102
	Unutar grupe	150,957	102	1,480		**2,70**
	Ukupno	170,274	105			
Zabava za goste u sobama * dob ispitanika	Između grupa	28,273	3	9,424	3,582	3;102
	Unutar grupe	268,331	102	2,631		**2,70**
	Ukupno	296,604	105			
Dostupnost interneta * dob ispitanika	Između grupa	25,398	3	8,466	4,271	3;102
	Unutar grupe	202,187	102	1,982		**2,70**
	Ukupno	227,585	105			
Kontrola ulaza * dob ispitanika	Između grupa	19,100	3	6,367	3,468	3;102
	Unutar grupe	187,249	102	1,836		**2,70**
	Ukupno	206,349	105			
Kontrola upravljanja minibarom * dob ispitanika	Između grupa	,821	3	,274	,172	3;94
	Unutar grupe	149,179	94	1,587		**2,70**
	Ukupno	150,000	97			
Upravljanje osvjetljenjem * dob ispitanika	Između grupa	8,768	3	2,923	1,919	3;102
	Unutar grupe	155,382	102	1,523		**2,70**
	Ukupno	164,151	105			
Upravljanje energijom* dob ispitanika	Između grupa	13,351	3	4,450	3,490	3;102
	Unutar grupe	130,046	102	1,275		**2,70**
	Ukupno	143,396	105			
Sigurnost * dob ispitanika	Između grupa	17,787	3	5,929	3,509	3;102
	Unutar grupe	172,336	102	1,690		**2,70**
	Ukupno	190,123	105			
Integriranost pametnih kartica * dob ispitanika	Između grupa	17,494	3	5,831	4,569	3;102
	Unutar grupe	130,167	102	1,276		**2,70**
	Ukupno	147,660	105			

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz predočene ANOVA tablice vidljivo je kako nema ujednačenih rezultata kod osnovnih usluga. Naime F granični je veći od F izračunatog za OU1, i OU2 te OU6, i OU7 što ukazuje na nezavisnost varijabli o ocjenjivaču, odnosno da dob ispitanika ne utječe na njihove stavove o

konkretnim osnovnim uslugama. Nasuprot tome kod svih ostalih osnovnih usluga starosna dob ispitanika ima utjecaj na stavove o pojedinim osnovnim uslugama.

b) Distribucija ocjene osnovnih usluga prema namjeni hotela

Primarna namjena hotela je atribut koji određuje hotel u odnosu na gosta, a time i njegova očekivanja. Budući da je gotovo 70% hotela deklarirano kao hoteli za odmor, to će, očekivano, i ta skupina dominirati pri ocjenjivanju prema apsolutnim pokazateljima.

Prosječne ocjene koje su izračunate na temelju podataka iz anketnog upitnika za svaku od osnovnih usluga – OU razvrstane su prema namjeni hotela te se predočavaju narednom tablicom.

Tablica 47. Prosječne ocjene osnovnih usluga prema namjeni hotela

DOB		OU1	OU2	OU3	OU4	OU5	OU6	OU7	OU8	OU9	OU10	OU11
Kongres	$\bar{X}$	9,88	9,25	8,50	7,38	9,50	9,88	8,00	8,88	8,25	9,38	9,38
	N	8	8	8	8	8	8	6	8	8	8	8
	SD	0,35	0,71	1,07	0,74	0,53	0,35	0,89	0,35	1,04	0,52	0,52
Odmor	$\bar{X}$	8,43	8,27	8,14	6,74	8,05	8,28	8,04	8,05	7,81	8,09	7,88
	N	74	74	74	74	74	74	70	74	74	74	74
	SD	0,99	0,96	1,22	1,83	1,43	1,39	1,27	1,22	1,11	1,34	1,10
Sport i zabava	$\bar{X}$	9,09	8,73	8,64	7,09	8,64	8,91	8,00	8,36	8,45	8,91	8,27
	N	11	11	11	11	11	11	11	11	11	11	11
	SD	0,83	1,27	1,21	1,04	1,50	1,38	1,10	1,21	1,04	1,30	0,79
Urbani	$\bar{X}$	8,33	8,56	7,22	5,78	7,33	8,11	7,56	7,89	8,00	7,89	6,78
	N	9	9	9	9	9	9	9	9	9	9	9
	SD	0,87	1,01	1,79	1,72	1,66	1,27	1,59	1,90	1,87	1,45	1,64
Zdrav. i *wellness*	$\bar{X}$	8,0	8,0	8,8	6,5	7,8	8,5	8,5	8,0	7,8	8,0	8,0
	N	4	4	4	4	4	4	2	4	4	4	4
	SD	1,15	1,41	0,50	0,58	1,50	1,91	0,71	1,41	0,96	1,41	0,00

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Istaknute su najveće prosječne ocjene OU s obzirom na namjenu hotela. Uočljiva je dominacija visokih ocjena osnovnih usluga kod kongresnih hotela slijedi analiza varijanci:

Tablica 48. Analiza varijance osnovnih usluga prema namjeni hotela

ANOVA		Zbroj kvadrata	df	Srednji kvadrati	F	F granični za 5% sign.
Telefonija i telefonske aplikacije * namjena hotela	Između grupa	19,790	4	4,947	5,555	3;102
	Unutar grupe	89,946	101	,891		**2,70**
	Ukupno	109,736	105			
Integracija fiksne i mobilne telefonije * namjena hotela	Između grupa	9,058	4	2,264	2,276	3;102
	Unutar grupe	100,499	101	,995		**2,70**
	Ukupno	109,557	105			
Hotelski sustav reklamiranja * namjena hotela	Između grupa	12,774	4	3,193	2,048	3;102
	Unutar grupe	157,500	101	1,559		**2,70**
	Ukupno	170,274	105			
Zabava za goste u sobama * namjena hotela	Između grupa	13,143	4	3,286	1,171	3;102
	Unutar grupe	283,461	101	2,807		**2,70**
	Ukupno	296,604	105			
Dostupnost interneta * namjena hotela	Između grupa	24,506	4	6,126	3,047	3;102
	Unutar grupe	203,079	101	2,011		**2,70**
	Ukupno	227,585	105			
Kontrola ulaza * namjena hotela	Između grupa	21,636	4	5,409	2,958	3;102
	Unutar grupe	184,714	101	1,829		**2,70**
	Ukupno	206,349	105			
Kontrola upravljanja minibarom * namjena hotela	Između grupa	2,406	4	,602	,379	3;94
	Unutar grupe	147,594	93	1,587		**2,70**
	Ukupno	150,000	97			
Upravljanje osvjetljenjem * namjena hotela	Između grupa	6,058	4	1,514	,968	3;102
	Unutar grupe	158,093	101	1,565		**2,70**
	Ukupno	164,151	105			
Upravljanje energijom * namjena hotela	Između grupa	5,068	4	1,267	,925	3;102
	Unutar grupe	138,329	101	1,370		**2,70**
	Ukupno	143,396	105			
Sigurnost * namjena hotela	Između grupa	18,112	4	4,528	2,659	3;102
	Unutar grupe	172,011	101	1,703		**2,70**
	Ukupno	190,123	105			
Integriranost pametnih kartica * namjena hotela	Između grupa	30,143	4	7,536	6,476	3;102
	Unutar grupe	117,518	101	1,164		**2,70**
	Ukupno	147,660	105			

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz predočene ANOVA tablice vidljivo je kako nema ujednačenih rezultata kod osnovnih usluga. Naime, F granični je veći od F izračunatog za OU2, OU3, OU4, OU7 i OU8 što ukazuje na nezavisnost varijabli o ocjenjivaču, odnosno da namjena hotela ne utječe na stavove ispitanika

o konkretnim osnovnim uslugama. Nasuprot tome kod svih ostalih osnovnih usluga namjena hotela ispitanika ima utjecaj na stavove o pojedinim osnovnim uslugama.

Različitosti utjecaja ili ne-utjecaja ispitanika na ocjene proizlaze iz njihove osobnosti, ali i okolnosti u kojima posluju. U kakvom su međusobnom odnosu osnovne usluge prema ocjenama ispitanika moguće je ustanoviti ako se ispita njihova korelacija što je prikazano narednom tablicom.

Tablica 49. Korelacija elemenata osnovnih usluga

	OU1	OU2	OU3	OU4	OU5	OU6	OU7	OU8	OU9	OU10	OU11
OU1	1	0,801	0,63	0,501	0,631	0,74	0,497	0,699	0,388	0,666	0,491
OU2	0,801	1	0,586	0,496	0,618	0,673	0,485	0,629	0,409	0,645	0,404
OU3	0,63	0,586	1	0,581	0,571	0,646	0,349	0,525	0,36	0,648	0,58
OU4	0,501	0,496	0,581	1	0,567	0,335	0,224	0,216	0,096	0,245	0,399
OU5	0,631	0,618	0,571	0,567	1	0,612	0,396	0,434	0,234	0,524	0,463
OU6	0,74	0,673	0,646	0,335	0,612	1	0,554	0,671	0,405	0,735	0,537
OU7	0,497	0,485	0,349	0,224	0,396	0,554	1	0,64	0,484	0,554	0,363
OU8	0,699	0,629	0,525	0,216	0,434	0,671	0,64	1	0,574	0,716	0,474
OU9	0,388	0,409	0,36	0,096	0,234	0,405	0,484	0,574	1	0,557	0,354
OU10	0,666	0,645	0,648	0,245	0,524	0,735	0,554	0,716	0,557	1	0,713
OU11	0,491	0,404	0,58	0,399	0,463	0,537	0,363	0,474	0,354	0,713	1

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Korelacija je računata Pearsonovim koeficijentom korelacije kojim se prepoznaje povezanost ako je koeficijent veći od 0,5. Uočavaju se različiti stupnjevi povezanosti pojedinih osnovnih usluga što znači da one međusobno ne korespondiraju. To ne umanjuje važnost istraživanja, već ukazuje na moguću nekoordiniranost postavljenih pitanja u upitniku. Analiza svih 11 osnovnih elemenata potvrdila je relevantnost uzorka od 106 ispitanika što je utvrđeno Bootstrap analizom na „pojačanju“ od 1.000 s 95% povjerenja.

1.27 Ocjena elemenata integriranih informacijsko-komunikacijskih usluga – konferencijske usluge

Konferencijske usluge čine element hotelske ponude bilo da se radi o hotelima specijaliziranim za kongrese i konferencije ili hotelima za odmor ili rekreaciju iz razloga što poslovni ljudi i na odmoru održavaju svoje poslovne kontakte, vode poduzeća ili upravljaju sportskim klubovima, a konferencije su superiorni i nezamjenjiv oblik komunikacije u poslovnom svijetu. Stoga se

usluge koje hotel pruža gostima za poslovne sastanke mogu smatrati osnovnim uslugama koje su integrirane u informatički sustav hotela. U nastavku se analizira kako su ispitanici ocijenili osnovne konferencijske usluge: 1) IP telefoniju i 2) videokonferencijske usluge i prijenos videosignala putem IP-a.

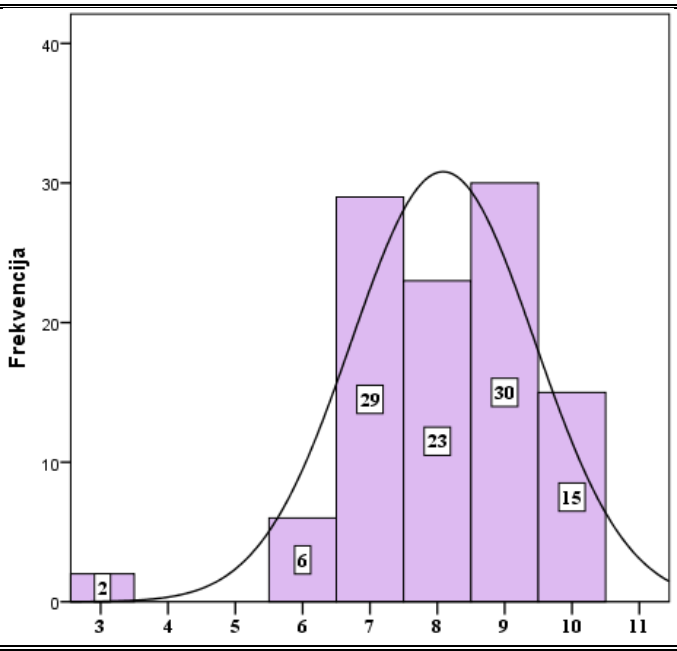
1.27.1 IP telefonija

IP telefonija omogućuje prijenos zvuka posredstvom računalne mreže pomoću internetskog protokola IP-a (engl. *Internet Protocol*). Ovaj komunikacijski kanal može funkcionirati na lokalnoj hotelskoj mreži ili preko interneta prema vanjskim korisnicima. Prednost nad klasičnim ili mobilnim telefonima ogleda se u mogućnostima konferencijskog komuniciranja (više korisnika istovremeno) kojima je dopušten i prijenos podataka.

Od ukupno 106 ispitanika njih 105 (99,1%) dalo je svoje ocjene ovom elementu. Samo jedan ispitanik (0,9%) nije odgovorio na postavljeno pitanja bez obrazloženja te se može pretpostaviti kako oni u svojem hotelu nemaju tu uslugu. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 50. Frekvencija i distribucija ocjena elementa IP telefonije

IP telefonija		F	%	Histogram ocjena elementa 12.
	3	2	1,9	
	6	6	5,7	
	7	29	27,6	
	8	23	21,9	
	9	30	28,6	
	10	15	14,3	
	Ukupno	105	100	
$\bar{X}$		8,087		
Medijan		8,00		
Mod		9,00		
SD		1,35954		
Varijanca σ^2		1,848		
Raspon		7		
Σ		849		
Skewness		-0,883		
Kurtosis		2,023		
Percentil	25	7		
	50	8		
	75	9		



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 50. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 3 do 10. Dva su ispitanika (1,9%) dodijelila ocjenu 3 dok je 15 ispitanika (14,3%) dodijelilo maksimalnu ocjenu 10. Ocjene 7, 8 i 9 su se isticale (ukupno 78,1%). Histogram 12. jasno predočava kako ocjene elementa IP telefonije ne prate normalnu razdiobu. Vidljiva je nepravilna varijabilnost koja vjerojatno proizlazi od različite veličine hotela. Mjera asimetrije normalne krivulje Skewness je umjerena i negativna -0,883 što ukazuje na umjeren pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 2,023 što označava umjerenu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom se tablicom predočavaju rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 51. Bootstrap analiza ocjena elementa IP telefonije

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8,0857	0,0009	0,1358	7,8	8,3521
Medijan	8	0,078	0,2683	8	9
SD	1,35954	-0,01148	0,13112	1,11915	1,62131
Varijanca σ^2	1,848	-0,014	0,358	1,253	2,629
Skewness	-0,883	0,104	0,394	-1,387	0,101
Kurtosis	2,023	-0,465	1,237	-1,134	3,295

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element IP telefonije ocijenili prosječnom ocjenom 8,0857 uz standardnu devijaciju od 1,35954 i varijancu 1,848. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

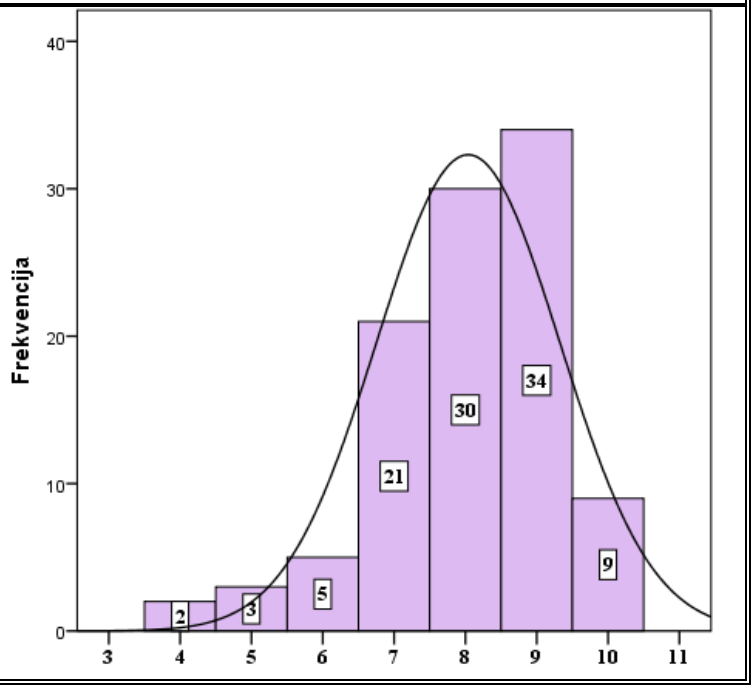
1.27.2 Videokonferencije

Videokonferencijske usluge i prijenos videosignala putem IP-a podrazumijevaju da hotel ima stabilnu širokopojasnu internetsku infrastrukturu. Naime, prijenos videosignala putem interneta mora biti besprijekoran jer u protivnom, ako postoje smetnje ili zastoji videosignala, odvlače pozornost sudionika. Stoga hoteli moraju obazrivo nuditi ovu uslugu u slučaju da nemaju potrebnu ICT infrastrukturu.

Od ukupno 106 ispitanika njih 104 (98,1%) dalo je svoje ocjene ovom elementu. Dvoje ispitanika (1,9%) nije odgovorilo na postavljeno pitanje bez obrazloženja te se može pretpostaviti kako oni u svojem hotelu nemaju tu uslugu. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 52. Frekvencija i distribucija ocjena elementa videokonferencija

Videokonferencije		F	%	Histogram ocjena elementa 13.
	4	2	1,9	
	5	3	2,9	
	6	5	4,8	
	7	21	20,2	
	8	30	28,8	
	9	34	32,7	
	10	9	8,7	
	Ukupno	104	100	
$\bar{X}$		8,0385		
Medijan		8,00		
Mod		9,00		
SD		1,28413		
Varijanca σ²		1,649		
Raspon		6		
Σ		836		
Skewness		-0,858		
Kurtosis		0,925		
Percentil	25	7		
	50	8		
	75	9		



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 52. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 4 do 10. Dva su ispitanika (1,9%) dodijelila ocjenu 4 dok je 9 ispitanika (8,7%) dodijelilo maksimalnu ocjenu 10. Ocjena 9 je istaknuta (32,7%). Histogram 13. jasno predočava kako ocjene elementa videokonferencije ne prate normalnu razdiobu. Vidljiva je nepravilna varijabilnost koja vjerojatno proizlazi od različite veličine hotela. Mjera asimetrije normalne krivulje Skewness je umjerena i negativna -0,858 što ukazuje na umjeren pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 0,925 što označava slabu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 53. Bootstrap analiza ocjena elementa videokonferencija

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8,0385	0,0048	0,1297	7,7981	8,2981
Medijan	8	0,042	0,1905	8	9
SD	1,28413	-0,01065	0,10651	1,06882	1,49379
Varijanca σ^2	1,649	-0,016	0,272	1,142	2,231
Skewness	-0,858	0,028	0,215	-1,223	-0,398
Kurtosis	0,925	-0,072	0,627	-0,274	2,164

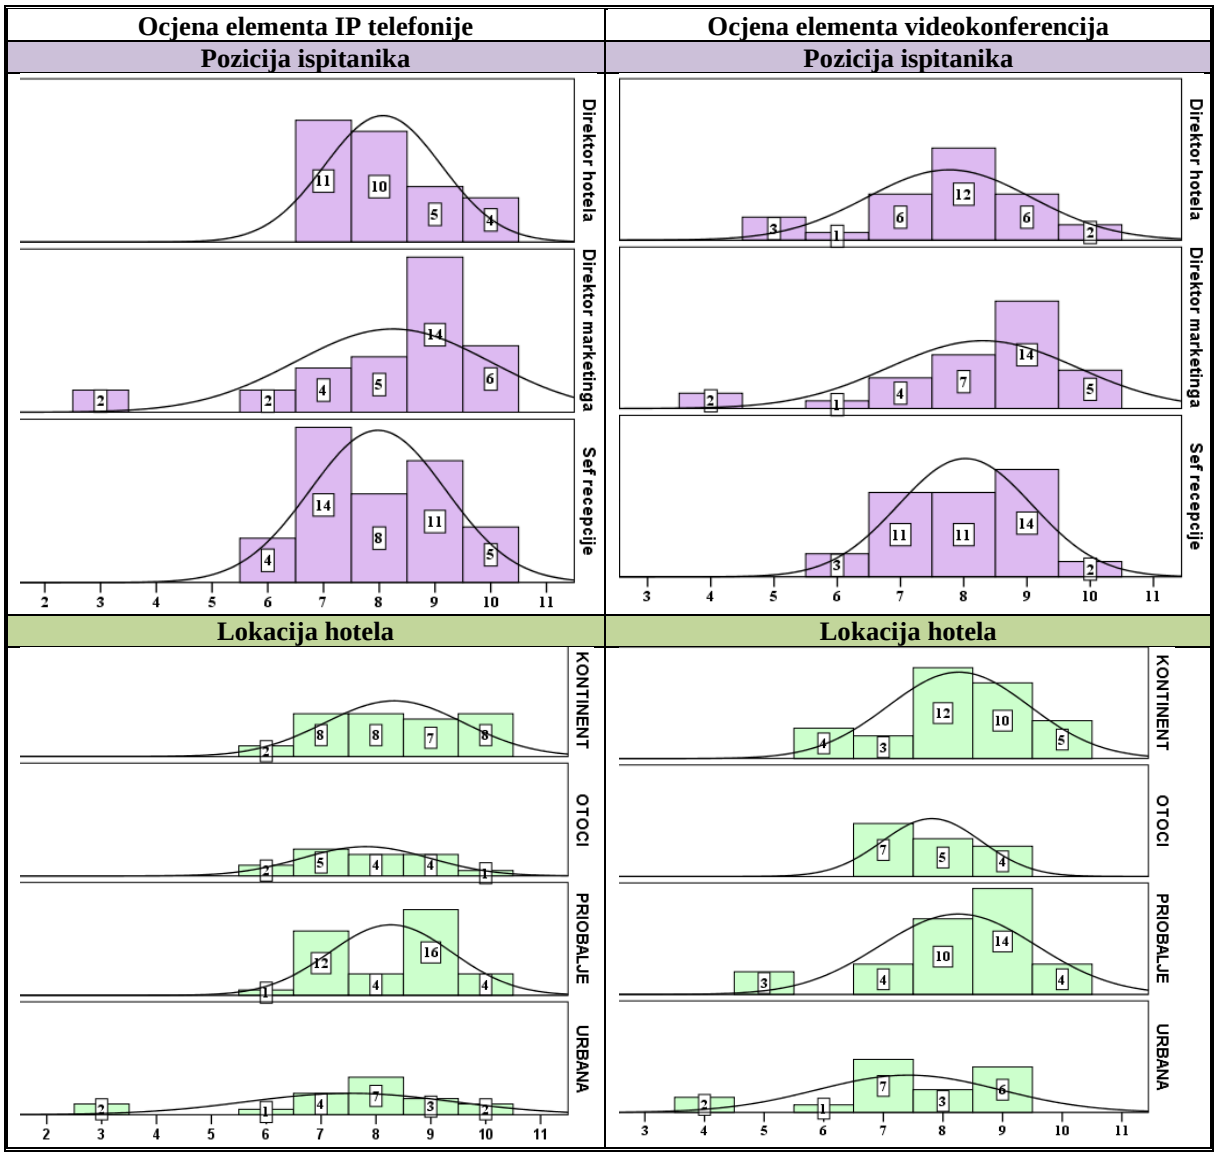
Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element videokonferencije ocijenili prosječnom ocjenom 8,0385 uz standardnu devijaciju od 1,28413 i varijancu 1,649. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

1.27.3 Analiza konferencijskih usluga integriranih informacijsko-komunikacijskih usluga u hotelu

Analiza polazi od pretpostavke H_0 kako su ocjene ispitanika ravnomjerno distribuirane bez obzira na poziciju koju ispitanik ima u hotelu kao i na lokaciju gdje se hotel nalazi. Nasuprot tome postavlja se hipoteza istraživanja H_I kojom se pretpostavlja da pozicija ispitanika i lokalitet hotela utječu na stupanj ocjenjivanja konferencijskih usluga integriranih informacijsko-komunikacijskih usluga u hotelu. Grafička analiza predočava se narednim složenim prikazom.

Grafikon 9. Grafička analiza distribucije ocjena konferencijskih usluga prema poziciji ispitanika i lokaciji hotela



Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Iz grafikona 9. vidljiva je distribucija dodijeljenih ocjena s obzirom na poziciju ispitanika u hotelu i lokalitet hotela, ali vizualno nije moguće ustanoviti njihovu ravnomjernost, a time i potvrđivanje/odbacivanje nul-hipoteze te je potrebno provesti dodatno χ^2 testiranje kako se to predočava narednim tablicama.

Tablica 54. χ^2 test značajnosti ocjena konferencijskih usluga prema poziciji ispitanika

χ^2 test				
Ocjene IP telefonije		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
3-10	Pearson χ^2	18,364	10	18,307
	Cramer's V	0,296		**$\chi^2 > \chi^2$ tablični odbacuje se H_0**
	Koeficijent kontingencije ***C***	0,386		
	Omjer izglednosti	20,621	10	
	N	105		
χ^2 test				
Ocjene videokonferencija		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
4-10	Pearson χ^2	21,454	12	21,026
	Cramer's V	0,321		**$\chi^2 > \chi^2$ tablični odbacuje se H_0**
	Koeficijent kontingencije ***C***	0,414		
	Omjer izglednosti	21,799		
	N	104		

Izvor: Izračun SPSS Statisticsa 21 temeljem podataka iz anketnog upitnika

Interpretacija dobivenih rezultata: s obzirom na to da je χ^2 izračunati > χ^2 graničnog za 5% statističke značajnosti odbacuje *se* H_0 o nezavisnosti promatranih varijabli te se ujedno i prihvaća izglednost da pozicija ispitanika utječe na dodjeljivanje ocjena konferencijskih usluga. Visoka vrijednost Cramerov V upućuje na asimetričnost ocjena, odnosno odstupanja od normalne razdiobe.

Tablica 55. χ^2 test značajnosti ocjena konferencijskih usluga prema lokaciji hotela

χ^2 test				
Ocjene IP telefonije		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
3-10	Pearson χ^2	26,014	15	24,996
	Cramer's V	0,478		**$\chi^2 > \chi^2$ tablični odbacuje se H_0**
	Koeficijent kontingencije ***C***	0,431		
	Omjer izglednosti	21,507	15	
	N	105		
χ^2 test				
Ocjene videokonferencije		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
4-10	Pearson χ^2	38,664	18	28,869
	Cramer's V	0,352		**$\chi^2 > \chi^2$ tablični odbacuje se H_0**
	Koeficijent kontingencije ***C***	0,521		
	Omjer izglednosti	40,731	18	
	N	104		

Izvor: Izračun SPSS Statisticsu 21 temeljem podataka iz anketnog upitnika

Interpretacija dobivenih rezultata: s obzirom na to da je χ^2 izračunati > χ^2 graničnog za 5% statističke značajnosti odbacuje *se* H_0 o nezavisnosti promatranih varijabli te se ujedno i

prihvaća izglednost da lokacija hotela utječe na dodjeljivanje ocjena konferencijskih usluga. Visoka vrijednost Cramerov V upućuje na asimetričnost ocjena, odnosno odstupanja od normalne razdiobe.

Analiza varijance provodi se za prethodno elaborirane elemente konferencijskih usluga: IP telefonije i videokonferencija. Postavlja se hipoteza istraživanja H_I kako dob ispitanika utječe na distribuciju ocjena konferencijskih usluga. Kako su ispitanici dodjeljivali svoje ocjene pojedinim elementima konferencijskih usluga i kakva je njihova međusobna povezanost u odnosu na dob ispitanika predočava se narednom tablicom.

Tablica 56. Analiza varijanci ocjena konferencijskih usluga prema dobi ispitanika

Dob ispitanika		**IP telefonija N = 106**	**Videokonferencije N = 106**
Do 35	$\bar{X}$	8,3529	7,875
	% od N	16,20%	15,40%
36-45	$\bar{X}$	8,3947	8,4615
	% od N	36,20%	37,50%
46-55	$\bar{X}$	8,0588	8,0588
	% od N	32,40%	32,70%
Više od 56	$\bar{X}$	7,125	7,0667
	% od N	15,20%	14,40%

ANOVA		**Zbroj kvadrata**	**df**	**Srednji kvadrati**	**F**	**F granični za 5% sign.**
IP telefonija * dob ispitanika	Između grupa	19,635	3	6,545	**3,83**	3;101
	Unutar grupe	172,594	101	1,709		**2,70**
	Ukupno	192,229	104			
Videokonferencije * dob ispitanika	Između grupa	21,588	3	7,196	**4,854**	3;100
	Unutar grupe	148,258	100	1,483		**2,70**
	Ukupno	169,846	103			

Izvor: Izračun SPSS Statisticsu 24 temeljem podataka iz anketnog upitnika

Kako je vidljivo iz ANOVA tablice 56., vrijednosti F izračunato veće su od F tablično za 5% statističke značajnosti što upućuje na to da valja odbaciti nul-hipotezu, odnosno prihvatiti u cijelosti postavljenu hipotezu istraživanja H_I kako dob ispitanika utječe na ocjenjivanje elemenata konferencijskih usluga.

1.28 Ocjena elemenata integriranih informacijsko-komunikacijskih usluga – interno oglašavanje

Interno oglašavanje je marketing unutar hotela posredstvom IT kanala komunikacije. Kada već postoji infrastruktura unutar hotela, tada je poželjno i da se iskoristi za promidžbu osnovnih i

dopunskih proizvoda i usluga koje hotel nudi. Njima se informiraju gosti o važnijim zbivanjima u hotelu, zabavi, druženjima, izletima, rekreacijskim programima i sl. Elementi koji se ocjenjuju jesu: 1) plazma ekrani, 2) infokiosci, 3) ekrani na VoIP telefonima u sobi, 4) IP televizije u sobama i 5) interne mrežne stranice i mrežni portali za goste.

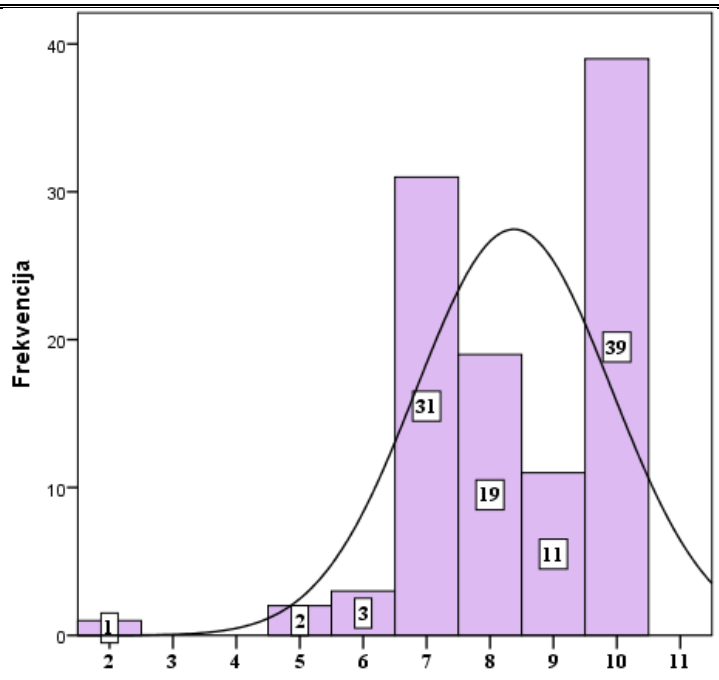
1.28.1 Plazma ekrani

Plazma ekrani jest uobičajen naziv za reklamne interaktivne ploče koje neovisno o tehnologiji (LED, plazma, LCD) nude mogućnost pružanja reklamnih poruka gostima hotela. U pravilu su to veliki ekrani postavljeni na prometnim mjestima koji odašilju (sa zvukom ili bez) slikovne ili video marketinški osmišljene poruke.

Svi su ispitanici (100%) ocijenili ovaj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 57. Frekvencija i distribucija ocjena elementa plazma ekrana

Plazma ekrani		F	%	Histogram ocjena elementa 14.
	2	1	0,9	
	5	2	1,9	
	6	3	2,8	
	7	31	29,2	
	8	19	17,9	
	9	11	10,4	
	10	39	36,8	
	Ukupno	106	100	
$\bar{X}$		8,3774		
Medijan		8		
Mod		10		
SD		1,53965		
Varijanca σ^2		2,371		
Raspon		8		
Σ		888		
Skewness		-0,770		
Kurtosis		1,209		
Percentil	25	7		
	50	8		
	75	10		



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 57. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 2 do 10. Jedan je ispitanik (0,9%) dodijelio ocjenu 2, dok je 39 ispitanika (36,8%) dodijelilo

maksimalnu ocjenu 10. Histogram 14. predočava kako ocjene elementa plazma ekrana ne prate normalnu razdiobu. Uočljiva je koncentracija oko ocjena 7 (29,2%) i 10, koju je dalo 36,8% ispitanika. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,770 što ukazuje na slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 1,209 što označava umjerenu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 58. Bootstrap analiza ocjena elementa plazma ekrana

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8,3774	0,0057	0,1471	8,066	8,6604
Medijan	8	0,289	0,4424	8	9
SD	1,53965	-0,0145	0,12608	1,31811	1,78894
Varijanca σ^2	2,371	-0,029	0,391	1,737	3,2
Skewness	-0,77	0,103	0,397	-1,364	0,032
Kurtosis	1,209	-0,543	1,529	-1,544	3,181

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element plazma ekrana ocijenili prosječnom ocjenom 8,3774 uz standardnu devijaciju od 1,53965 i varijancu 2,371. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

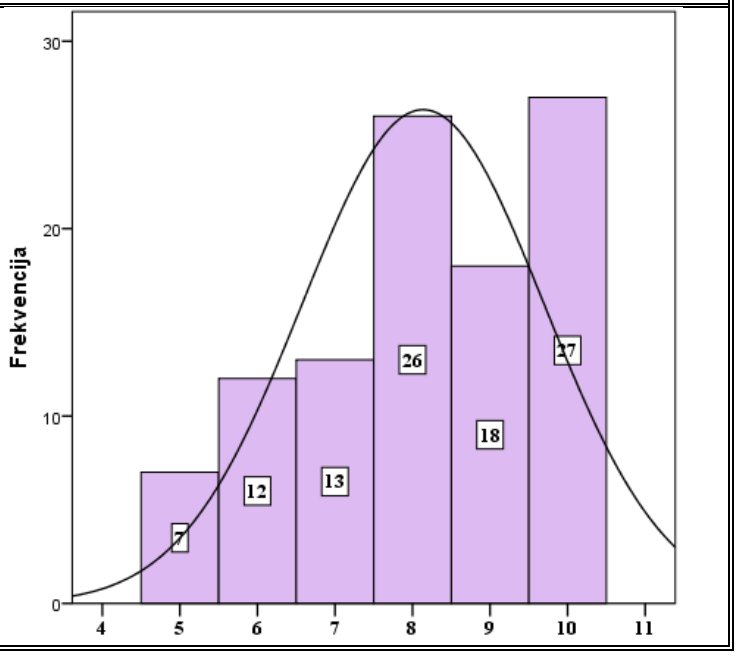
1.28.2 Infokiosci

Infokiosci su koristan marketinški kanal objavljivanja gostima zanimljivih informacija od dnevnih novosti i događaja u okruženju do menija za večeru. Postavljaju se na prometnim mjestima, a sadržaji su prilagođeni vrsti hotela.

Od ukupno 106 ispitanika njih 103 (97,3%) dalo je svoje ocjene ovom elementu. Tri ispitanika (2,8%) nisu odgovorila na postavljeno pitanje bez obrazloženja te se može pretpostaviti kako oni u svojem hotelu nemaju tu uslugu. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 59. Frekvencija i distribucija ocjena elementa infokioska

Infokiosk		F	%
	5	7	6,8
	6	12	11,7
	7	13	12,6
	8	26	25,2
	9	18	17,5
	10	27	26,2
	Ukupno	103	100
$\bar{X}$		8,1359	
Medijan		8,00	
Mod		10,00	
SD		1,55959	
Varijanca σ²		2,432	
Raspon		5	
Σ		838	
Skewness		-0,436	
Kurtosis		-0,833	
Percentil	25	7	
	50	8	
	75	10	



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 59. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 5 do 10. Sedam je ispitanika (6,8%) dodijelilo ocjenu 5 dok je 27 ispitanika (26,2%) dodijelilo maksimalnu ocjenu 10. Ocjena 8 je istaknuta (25,2%). Histogram 15. jasno predočava kako ocjene elementa infokiosk ne prate normalnu razdiobu. Vidljiva je nepravilna varijabilnost koja vjerojatno proizlazi od različite veličine hotela. Mjera asimetrije normalne krivulje Skewness je umjerena i negativna -0,436 što ukazuje na umjeren pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -0,833 što označava slabu platikurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 60. Bootstrap analiza ocjena elementa infokioska

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8,1359	0,0018	0,1538	7,8252	8,4366
Medijan	8	0,106	0,308	8	9
SD	1,55959	-0,00706	0,07999	1,38466	1,70606
Varijanca σ²	2,432	-0,016	0,248	1,917	2,911
Skewness	-0,436	0	0,138	-0,7	-0,17

Kurtosis	-0,833	0,018	0,226	-1,184	-0,325

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element infokiosk ocijenili prosječnom ocjenom 8,1359 uz standardnu devijaciju od 1,55959 i varijancu 2,432. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

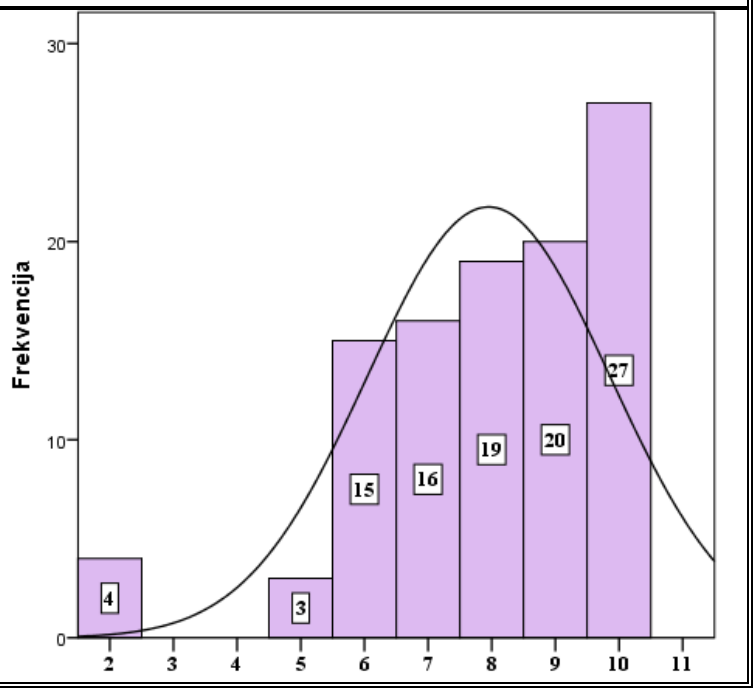
1.28.3 Ekrani na VoIP telefonima u sobi

Ekrani na VoIP telefonima u sobi važan su dio integriranih informacijsko-komunikacijskih usluga koje hotel nudi. Gost ima širok spektar mogućnosti korištenja uređaja bez dodatnih troškova od naručivanja buđenja, posluživanja u sobi do interkontinentalnih razgovora posredstvom interneta.

Od ukupno 106 ispitanika njih 104 (98,1%) dalo je svoje ocjene ovom elementu. Dvoje ispitanika (1,9%) nije odgovorilo na postavljeno pitanje bez obrazloženja te se može pretpostaviti kako oni u svojem hotelu nemaju tu uslugu. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 61. Frekvencija i distribucija ocjena elementa ekrana na VoIP telefonima u sobi

Plazma ekrani		**F**	**%**	**Histogram ocjena elementa 16.**
	2	4	3,8	
	5	3	2,9	
	6	15	14,4	
	7	16	15,4	
	8	19	18,3	
	9	20	19,2	
	10	27	26	
	Ukupno	104	100	
$\bar{X}$		7,9519		
Medijan		8,00		
Mod		10		
SD		1,90747		
Varijanca σ^2		3,638		
Raspon		8		
Σ		827		
Skewness		-1,128		
Kurtosis		1,558		
Percentil	25	7		
	50	8		
	75	10		



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 61. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 2 do 10. Četvero je ispitanika (3,8%) dodijelio ocjenu 2 dok je 27 ispitanika (26,0%) dodijelilo maksimalnu ocjenu 10. Histogram 16. predočava kako ocjene elementa ekrana na VoIP telefonima u sobi ne prate normalnu razdiobu. Uočljiva je koncentracija oko ocjena 9 i 10 (ukupno 45,2%). Mjera asimetrije normalne krivulje Skewness je izražena i negativna -1,128 što ukazuje umjereni pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 1,558 što označava umjerenu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 62. Bootstrap analiza ocjena elementa ekrana na VoIP telefonima u sobi

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	7,9519	0,0011	0,181	7,5769	8,3074
Medijan	8	0,1485	0,3483	8	9
SD	1,90747	-0,02165	0,16938	1,55243	2,23477
Varijanca σ^2	3,638	-0,053	0,643	2,41	4,994
Skewness	-1,128	0,063	0,235	-1,453	-0,509
Kurtosis	1,558	-0,17	0,684	-0,015	2,737

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element ekrana na VoIP telefonima u sobi ocijenili prosječnom ocjenom 7,9519 uz standardnu devijaciju od 1,90747 i varijancu 3,638. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

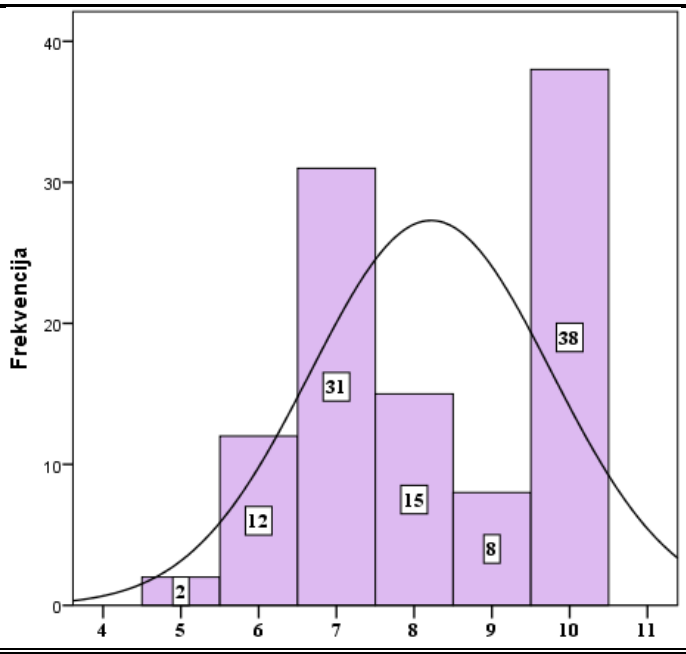
1.28.4 IP televizije u sobama

IP televizije u sobama dio su integriranog informacijsko-komunikacijskih usluga koje omogućuju praćenje TV i videosadržaja, telefoniranje i pristup internetu korištenjem jedinstvene mrežne infrastrukture za prijenos slike, glasa i podataka. IP TV omogućuje praćenje zemaljskih i satelitskih programa kao i programa „na zahtjev“ uz dodatnu naplatu.

Svi su ispitanici (100%) ocijenili ovaj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 63. Frekvencija i distribucija ocjena elementa IP televizija u sobama

IP televizije u sobama		F	%	Histogram ocjena elementa 17.
	5	2	1,9	
	6	12	11,3	
	7	31	29,2	
	8	15	14,2	
	9	8	7,5	
	10	38	35,8	
	Ukupno	106	100	
$\bar{X}$		8,2170		
Medijan		8,00		
Mod		10		
SD		1,54922		
Varijanca σ^2		2,400		
Raspon		5		
Σ		871		
Skewness		-0,089		
Kurtosis		-1,409		
Percentil	25	7		
	50	8		
	75	10		



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 63. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 5 do 10. Dvoje je ispitanika (1,9%) dodijelio ocjenu 5 dok je 38 ispitanika (35,8%) dodijelilo maksimalnu ocjenu 10. Histogram 17. predočava kako ocjene elementa IP televizija u sobama ne prate normalnu razdiobu. Uočljiva je koncentracija oko ocjena 7 (29,2%) i 10 koju je dalo 35,8% ispitanika. Mjera asimetrije normalne krivulje Skewness je vrlo slaba i negativna -0,089 što ukazuje na vrlo slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -1,409 što označava umjerenu platikurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 64. Bootstrap analiza ocjena elementa IP televizija u sobama

Statistika	Bootstrap N = 1.000		
		Standardna	95% Interval povjerenja

		Bias – sustavna pogreška	pogreška	Donja granica	Gornja granica
$\bar{X}$	8,217	-0,0012	0,1496	7,9245	8,5189
Medijan	8	0,0355	0,3683	7	9
SD	1,54922	-0,00986	0,05852	1,42261	1,64973
Varijanca σ²	2,4	-0,027	0,18	2,024	2,722
Skewness	-0,089	0,015	0,166	-0,435	0,24
Kurtosis	-1,409	0,014	0,131	-1,626	-1,12

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element IP televizija u sobama ocijenili prosječnom ocjenom 8,217 uz standardnu devijaciju od 1,54922 i varijancu 2,4. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

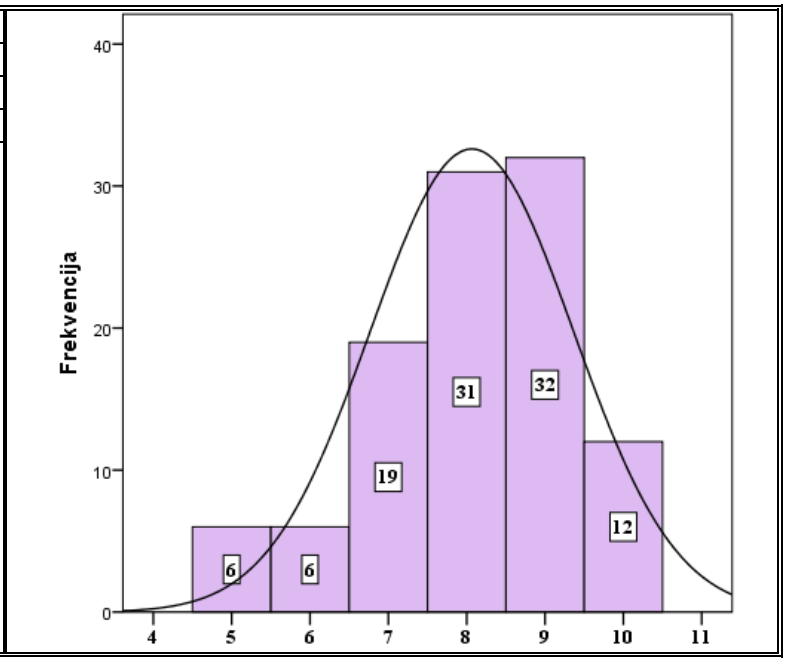
1.28.5 Interne mrežne stranice i mrežni portali za goste

Potreba za razvijanje internih mrežnih stranica i mrežnih portala namijenjenih isključivo gostima hotela javila se u hotelima čija je ponuda dodatnih sadržaja široka i koja zahtijevaju interakciju s gostom. Šira primjena ovog elementa dolazi do izražaja razvojem aplikacija za mobilne telefone kojima se gost priključuje ne internu hotelsku mrežu. Time je omogućena stabilna interakcija gosta i hotela u svakom trenutku neovisno je li gost u sobi, restoranu, teretani ili teniskom igralištu. Svi su ispitanici (100%) ocijenili ovaj element. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 65. Frekvencija i distribucija ocjena elementa internih mrežnih stranica i mrežnih portala za goste

Interne mrežne stranice i mrežni portali za goste		F	%	Histogram ocjena elementa 18.
	5	6	5,7	
	6	6	5,7	
	7	19	17,9	
	8	31	29,2	
	9	32	30,2	
	10	12	11,3	
	Ukupno	106	100	
$\bar{X}$		8,0660		
Medijan		8,0		
Mod		9,0		
SD		1,29665		
Varijanca σ²		1,681		
Raspon		5		
Σ		855		

Skewness		-0,606
Kurtosis		-0,033
Percentil	25	7
	50	8
	75	9



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 39. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 5 do 10. Šestero je ispitanika (5,7%) dodijelio ocjenu 5 dok je 12 ispitanika (11,3%) dodijelilo maksimalnu ocjenu 10. Histogram 18. predočava kako ocjene elementa internih mrežnih stranica i mrežnih portala za goste prate normalnu razdiobu. Uočljiva je koncentracija oko ocjena 8 i 9 (ukupno 59,4%). Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,606 što ukazuje na slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -0,033 što označava vrlo slabu platikurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 66. Bootstrap analiza ocjena elementa internih mrežnih stranica i mrežnih portala za goste

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	8,066	-0,0007	0,1301	7,8113	8,3208
Medijan	8	0,0495	0,2021	8	9
SD	1,29665	-0,01131	0,08375	1,11367	1,44342
Varijanca σ^2	1,681	-0,022	0,214	1,24	2,083
Skewness	-0,606	0,01	0,156	-0,887	-0,269
Kurtosis	-0,033	0,01	0,333	-0,573	0,713

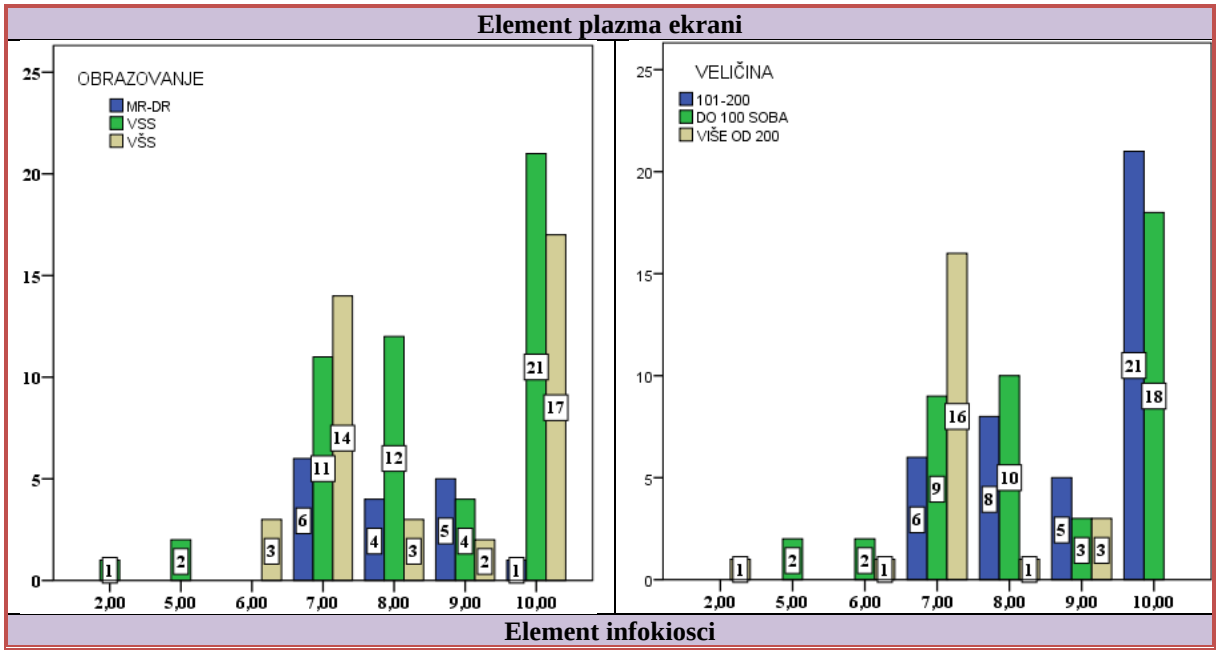
Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

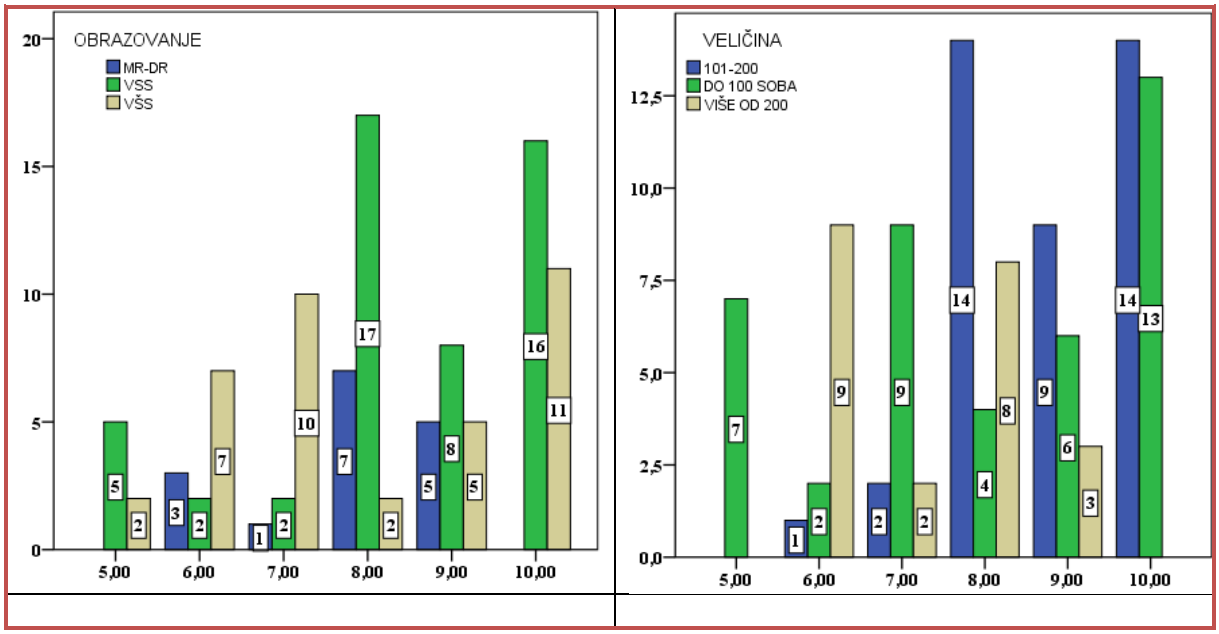
Ispitanici su element interne mrežne stranice i mrežne portale za goste ocijenili prosječnom ocjenom 8,066 uz standardnu devijaciju od 1,29665 i varijancu 1,681. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

1.28.6 Analiza internog oglašavanja u sklopu integriranih informacijsko-komunikacijskih usluga

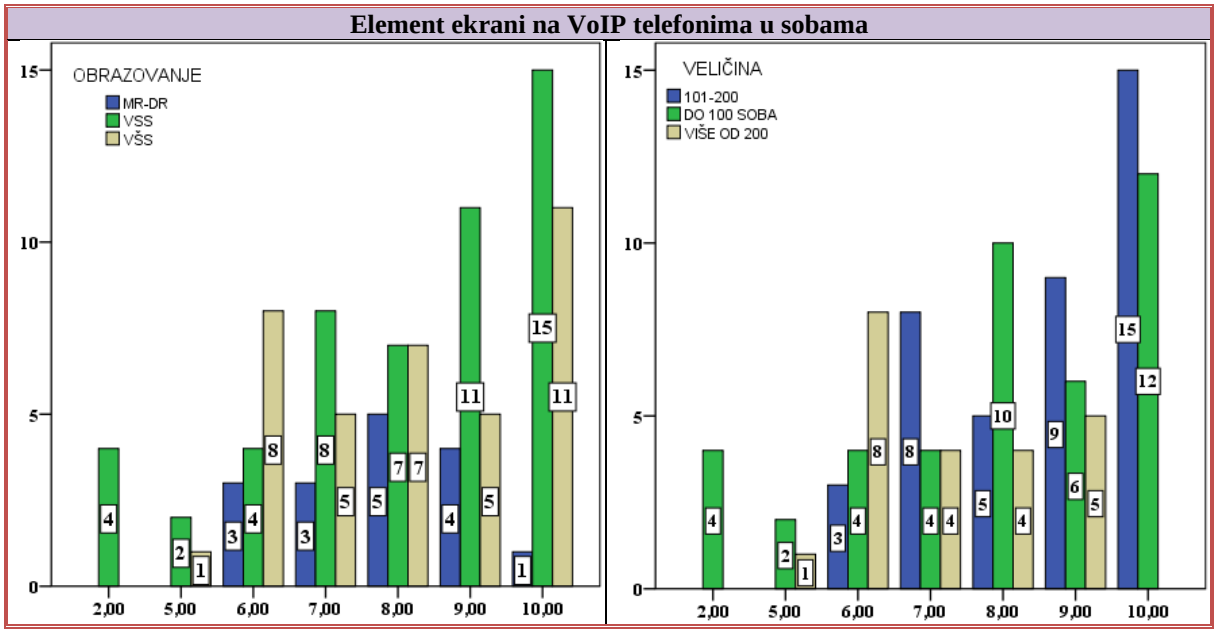
Analiza polazi od pretpostavke H_0 kako su ocjene ispitanika ravnomjerno distribuirane bez obzira na stupanj obrazovanja kao i na veličinu hotela. Nasuprot tome postavlja se hipoteza istraživanja H_I kojom se pretpostavlja da obrazovanje ispitanika i veličina hotela utječu na stupanj ocjenjivanja internog oglašavanja integriranih informacijsko-komunikacijskih usluga u hotelu. Grafička analiza predočava se narednim složenim prikazom.

Grafikon 10. Grafička analiza elemenata internog oglašavanja (I)

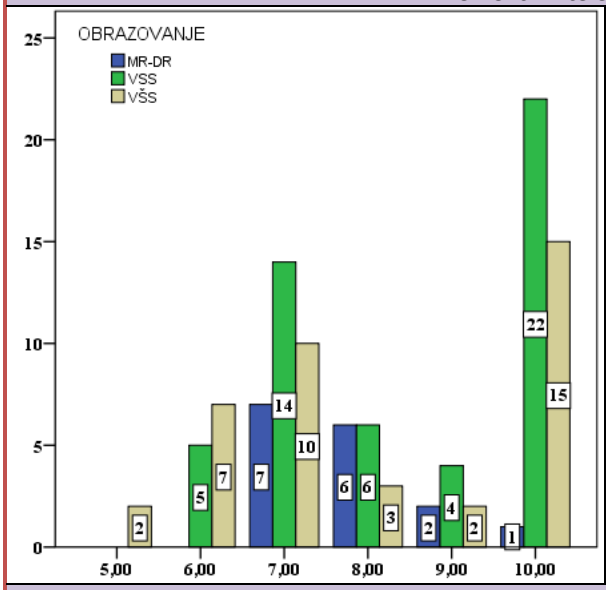


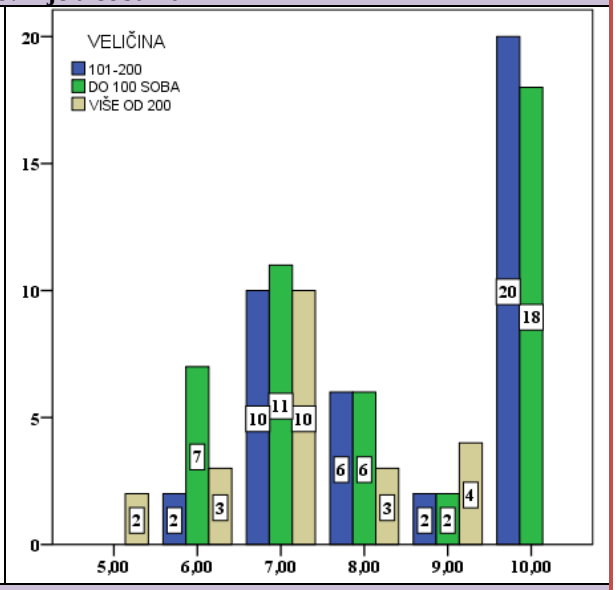


Grafikon 11. Grafička analiza elemenata internog oglašavanja (II)

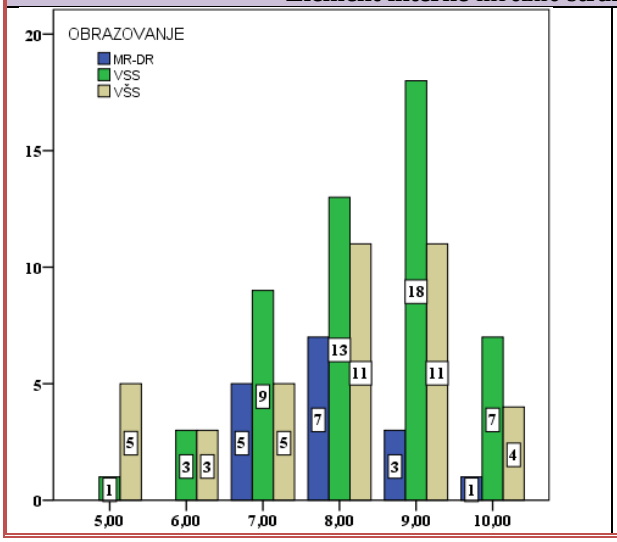


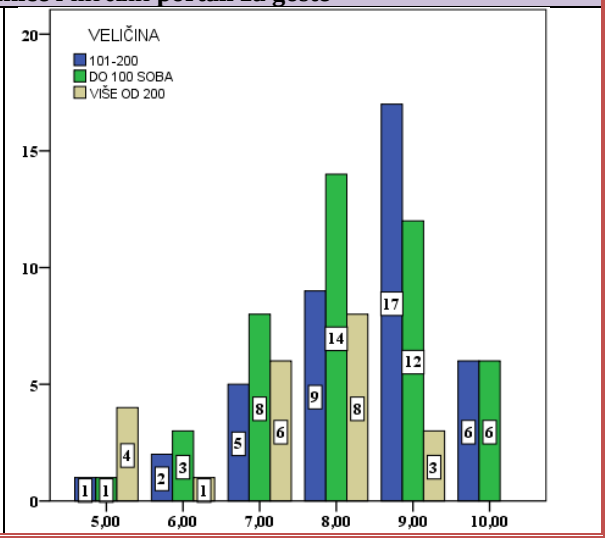
Element IP televizije u sobama





Element interne mrežne stranice i mrežni portali za goste





Iz grafikona 10. i 11. vidljiva je distribucija dodijeljenih ocjena s obzirom na obrazovanje ispitanika i veličinu hotela, ali vizualno nije moguće ustanoviti njihovu ravnomjernost, a time i potvrđivanje/odbacivanje nul-hipoteze te je potrebno provesti dodatno χ^2 testiranje kako se to predočava narednim tablicama.

Tablica 67. χ^2 test značajnosti ocjena internog oglašavanja prema obrazovanju ispitanika

χ^2 test				
Ocjene elementa plazma ekrana		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
2-10	Pearson χ^2	26,880	12	21,026
	Cramer's V	0,356		**$\chi^2 > \chi^2$ tablični odbacuje se H_0**
	Koeficijent kontingencije ***C***	0,450		
	Omjer izglednosti	29,440	12	
	N	106		
χ^2 test				

Ocjene elementa infokioska		Vrijednost	df	Tablična vrijednost χ^2 za df i 5% sign.
5-10	Pearson χ^2	32,970	10	18,307
	Cramer's V	0,400		$\chi^2 > \chi^2$ tablični odbacuje se H_0
	Koeficijent kontingencije ***C***	0,492		
	Omjer izglednosti	40,182	10	
	N	105		
χ^2 test				
Ocjene elementa ekrana na VoIP telefonima u sobama		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
2-10	Pearson χ^2	14,028	12	21,026
	Cramer's V	0,260		$\chi^2 < \chi^2$ tablični prihvaća se H_0
	Koeficijent kontingencije ***C***	0,345		
	Omjer izglednosti	17,006	12	
	N	104		
χ^2 test				
Ocjene elementa IP televizija		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
4-10	Pearson χ^2	21,332	10	18,307
	Cramer's V	0,317		$\chi^2 > \chi^2$ tablični odbacuje se H_0
	Koeficijent kontingencije ***C***	0,409		
	Omjer izglednosti	23,610	10	
	N	106		
χ^2 test				
Ocjene elementa mrežnih stranica hotela		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
3-10	Pearson χ^2	12,279	10	18,307
	Cramer's V	0,241		$\chi^2 < \chi^2$ tablični prihvaća se H_0
	Koeficijent kontingencije ***C***	0,322		
	Omjer izglednosti	13,313	10	
	N	106		

Izvor: Izračun SPSS Statisticsa 21 temeljem podataka iz anketnog upitnika

Interpretacija dobivenih rezultata: obrazovanje ispitanika pokazalo se kao faktor različitosti kada je u pitanju odnos prema elementima internog oglašavanja. Naime, hi kvadrat test pokazao je da se ravnomjernost distribucije ocjena postiže kod elemenata ekrana na VoIP telefonima i mrežnih stranica i mrežnih portala za goste što znači da obrazovanje ne utječe na ocjenjivanje tih dvaju elemenata što nije bio slučaj za elemente plazma ekrane, infokioske i IP televizije u sobama gdje su stavovi prema obrazovanju došli do izražaja. Visoka vrijednost Cramerov V upućuje na asimetričnost ocjena, odnosno odstupanja od normalne razdiobe.

Tablica 68. χ^2 test značajnosti ocjena konferencijskih usluga prema veličini hotela

χ^2 test				
Ocjene elementa plazma ekrana		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
2-10	Pearson χ^2	41,390	12	21,026
	Cramer's V	0,625		$\chi^2 > \chi^2$ tablični odbacuje se H_0
	Koeficijent kontingencije ***C***	0,530		
	Omjer izglednosti	47,696	12	

	N	106		
χ^2 test				
Ocjene elementa infokioska		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
5-10	Pearson χ^2	50,977	10	18,307
	Cramer's V	0,497		**$\chi^2 > \chi^2$ tablični odbacuje se H_0**
	Koeficijent kontingencije ***C***	0,575		
	Omjer izglednosti	55,247		
	N	103		
χ^2 test				
Ocjene elementa ekrana na VoIP telefonima u sobama		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
2-10	Pearson χ^2	28,960	12	21,026
	Cramer's V	0,373		**$\chi^2 > \chi^2$ tablični odbacuje se H_0**
	Koeficijent kontingencije ***C***	0,467		
	Omjer izglednosti	35,142	12	
	N	104		
χ^2 test				
Ocjene elementa IP televizija		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
4-10	Pearson χ^2	27,099	10	18,307
	Cramer's V	0,358		**$\chi^2 > \chi^2$ tablični odbacuje se H_0**
	Koeficijent kontingencije ***C***	0,451		
	Omjer izglednosti	32,586	10	
	N	106		
χ^2 test				
Ocjene elementa mrežnih stranica hotela		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
2-10	Pearson χ^2	18,015	10	18,307
	Cramer's V	0,292		**$\chi^2 < \chi^2$ tablični prihvaća se H_0**
	Koeficijent kontingencije ***C***	0,381		
	Omjer izglednosti	18,878		
	N	106		

Izvor: Izračun SPSS Statisticsa 21 temeljem podataka iz anketnog upitnika

Interpretacija dobivenih rezultata: osim u testiranju elementa IP televizija χ^2 izračunati > χ^2 graničnog za 5% statističke značajnosti odbacuje *se* H_0 o nezavisnosti promatranih varijabli te se ujedno i prihvaća izglednost da veličina hotela utječe na dodjeljivanje ocjena internog oglašavanja. Visoka vrijednost Cramerov V upućuje na asimetričnost ocjena, odnosno odstupanja od normalne razdiobe.

Analiza varijance provodi se za prethodno elaborirane elemente usluga internog oglašavanja. Postavlja se hipoteza istraživanja H_I kako dob ispitanika utječe na distribuciju ocjena internog oglašavanja.

Kako su ispitanici dodjeljivali svoje ocjene pojedinim elementima internog oglašavanja i kakva je njihova međusobna povezanost u odnosu na dob ispitanika predočava se narednom tablicom.

Tablica 69. Analiza varijanci ocjena usluga internog oglašavanja prema dobi ispitanika

Dob ispitanika		Plazma ekrani	Infokiosci	Ekrani na VoIP telefonima	IP televizije	Mrežne stranice hotela
Do 35	$\bar{X}$	8,8235	8,1333	8,0625	8,6471	8,2353
	% od N	17	15	16	17	17
36-45	$\bar{X}$	8,6154	8,6579	8,5	8,5641	8,3333
	% od N	39	38	38	39	39
46-55	$\bar{X}$	8,2353	7,9706	7,7647	8,0588	8
	% od N	34	34	34	34	34
Više od 56	$\bar{X}$	7,625	7,25	6,9375	7,25	7,375
	% od N	16	16	16	16	16

ANOVA		Zbroj kvadrata	df	Srednji kvadrati	F	F granični za 5% sign.
Plazma ekrani * dob ispitanika	Između grupa	15,337	3	5,112	**2,233**	3;102
	Unutar grupe	233,569	102	2,29		**2,70**
	Ukupno	248,906	105			
Infokiosci * dob ispitanika	Između grupa	23,841	3	7,947	**3,508**	3;99
	Unutar grupe	224,257	99	2,265		**2,70**
	Ukupno	248,097	102			
Ekrani na VoIP * dob ispitanika	Između grupa	29,267	3	9,756	**2,824**	3;100
	Unutar grupe	345,493	100	3,455		**2,70**
	Ukupno	374,76	103			
IP televizije * dob ispitanika	Između grupa	23,655	3	7,885	**3,522**	3;102
	Unutar grupe	228,354	102	2,239		**2,70**
	Ukupno	252,009	105			
Mrežne stranice hotela * dob ispitanika	Između grupa	11,062	3	3,687	**2,273**	3;102
	Unutar grupe	165,475	102	1,622		**2,70**
	Ukupno	176,538	105			

Izvor: Izračun SPSS Statisticsa 24 temeljem podataka iz anketnog upitnika

Interpretacija: kako je vidljivo iz ANOVA tablice 46. vrijednosti F izračunato su manje od F tablično za 5% statističke značajnosti za elemente plazma ekrane i mrežne stranice hotela što u tim slučajevima potvrđuje nul-hipotezu o ravnomjernosti distribucije ocjene neovisno o dobi ispitanika. Nasuprot tome kod elemenata infokioska, ekrana na VoIP telefonima i IP televizija u sobama uočljiva je zavisnost ocjenjivanja o dobnim skupinama ispitanika te se odbacuje nul-hipoteza i prihvaća hipoteza istraživanja H_I.

Shodno detektiranim različitostima koje se uočavaju pri interpretaciji rezultata pristupa se analizi korelacije srednjih vrijednosti ocjena promatranih 5 elemenata internog oglašavanja u hotelu.

Tablica 70. Korelacija prosječnih ocjena elemenata usluge internog oglašavanja

		Elementi internog oglašavanja				
Funkcija	**Elementi internog oglašavanja**	1	2	3	4	5
1	Plazma ekrani	1	0,673	0,641	0,676	0,536

2	Infokiosci	0,673	1	0,779	0,68	0,569
3	Ekrani na VoIP telefonima u sobama	0,641	0,779	1	0,699	0,56
4	IP televizije u sobama	0,676	0,68	0,699	1	0,766
5	Mrežne stranice hotela i mrežni portali	0,536	0,569	0,56	0,766	1

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Korelacija je računata Pearsonovim koeficijentom korelacije kojim se prepoznaje povezanost ako je koeficijent veći od 0,5. Ovime je potvrđena relevantnost poznavatelja s obzirom na to da su elementi usluga internog oglašavanja kreirani na način da djeluju koordinirano.

1.29 Ocjena elemenata integriranih informacijsko-komunikacijskih usluga – ostale usluge

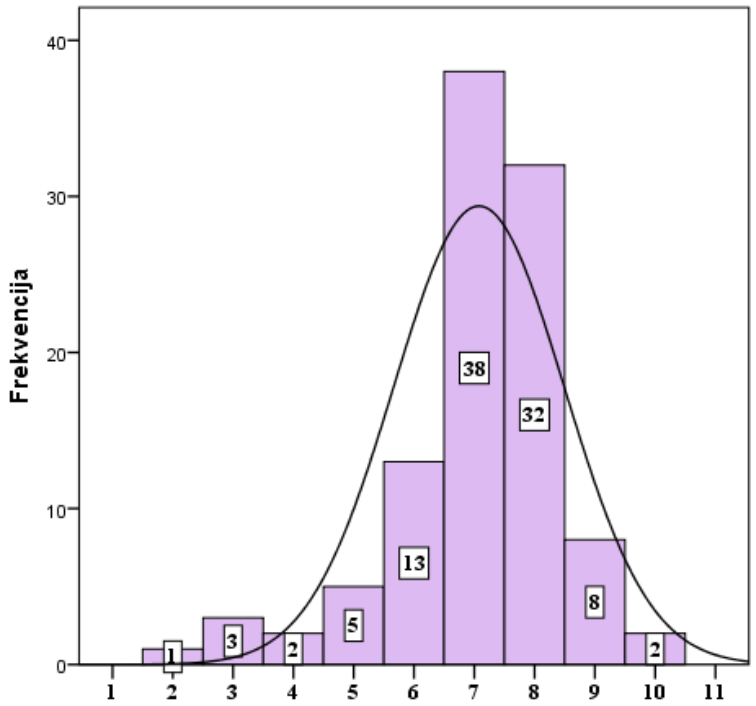
Od ostalih usluga koje su integrirane u informacijsko-komunikacijski sustav hotela izdvojene su i ispitanicima ponuđene na ocjenjivanje: 1) interaktivne informacije o događanjima u destinaciji, 2) interaktivna rezervacija restorana i 3) interaktivna rezervacija rekreativnih sadržaja.

1.29.1 Interaktivne informacije o događanjima u destinaciji

Svakom hotelijeru je u interesu da gost što više koristi hotelsku ponudu dodatnih sadržaja, ali isto tako i da koristi sadržaje koje nudi okruženje čime se upotpunjuje dojam i dobiva lojalnost. Stoga je uputno koristiti sve dostupne kanale komunikacije kako bi goste informirao o događanjima u destinaciji i aktivno sudjelovati u odabiru događaja, rezervaciji mjesta, organiziranju prijevoza i sl.

Od ukupno 106 ispitanika njih 104 (98,1%) je dalo svoje ocijene ovom elementu. Dvoje ispitanika (1,9%) nije odgovorilo na postavljeno pitanje bez obrazloženja te se može pretpostaviti kako oni u svojem hotelu ne pružaju tu uslugu. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 71. Frekvencija i distribucija ocjena elementa interaktivnih informacija o događanjima u destinaciji

Interaktivne informacije o događanjima u destinaciji		F	%	Histogram ocjena elementa 19.
	2	1	1	
	3	3	2,9	
	4	2	1,9	
	5	5	4,8	
	6	13	12,5	
	7	38	36,5	
	8	32	30,8	
	9	8	7,7	
	10	2	1,9	
	Ukupno	104	100	
$\bar{X}$		7,0769		
Medijan		7		
Mod		7		
SD		1,4121		
Varijanca σ^2		1,994		
Raspon		8		
Σ		736		
Skewness		-1,130		
Kurtosis		2,247		
Percentil	25	7		
	50	7		
	75	8		

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 71. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 2 do 10. Jedan je ispitanik (1,0%) dodijelio ocjenu 2 dok su 2 ispitanika (1,9%) dodijelila maksimalnu ocjenu 10. Histogram 19. predočava kako ocjene elementa interaktivnih informacija o događanjima u destinaciji prate normalnu razdiobu. Uočljiva je koncentracija oko ocjena 7 i 8 (ukupno 67,3%). Mjera asimetrije normalne krivulje Skewness je umjerena i negativna -1,130 što ukazuje na umjeren pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 2,247 što označava vrlo umjerenu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 72. Bootstrap analiza ocjena elementa interaktivnih informacija o događanjima u destinaciji

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	7,0769	0,0039	0,1376	6,7887	7,3365
Medijan	7	0,0265	0,1519	7	7,5
SD	1,4121	-0,00879	0,1356	1,14492	1,66003

Varijanca σ²	1,994	-0,006	0,381	1,311	2,756
Skewness	-1,13	0,049	0,283	-1,637	-0,505
Kurtosis	2,247	-0,122	0,916	0,582	4,218

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element interaktivne informacije o događanjima u destinaciji ocijenili prosječnom ocjenom 7,0769 uz standardnu devijaciju od 1,4121 i varijancu 1,994. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

1.29.2 Interaktivna rezervacija restorana

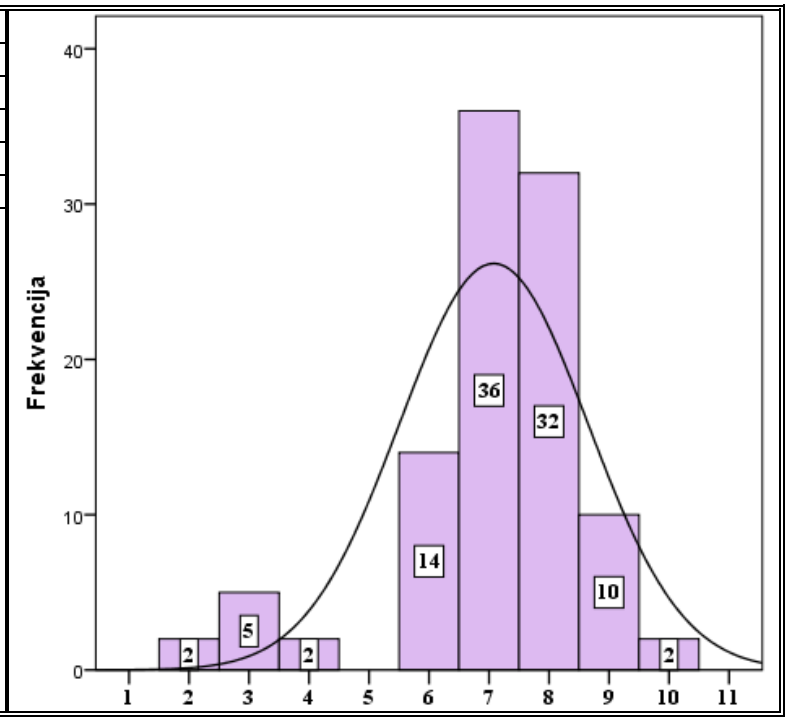
Interaktivna rezervacija restorana omogućuje gostu da sa svog pametnog telefona ili računala rezervira stol u restoranu, odabere smještaj, vrijeme i meni. Hotel raspolaže informacijom i prema njoj obavlja raspored stolova u restoranu, obavještava kuhinju, nabavlja i priprema namirnice čime je upotpunjena interakcija.

Od ukupno 106 ispitanika njih 104 (98,1%) je dalo svoje ocjene ovom elementu. Dvoje ispitanika (1,9%) nije odgovorilo na postavljeno pitanje bez obrazloženja te se može pretpostaviti kako oni u svojem hotelu ne pružaju tu uslugu. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 73. Frekvencija i distribucija ocjena elementa interaktivne rezervacije restorana

Interaktivna rezervacija restorana		**F**	**%**	**Histogram ocjena elementa 20.**
	2	2	1,9	
	3	5	4,9	
	4	2	1,9	
	6	14	13,6	
	7	36	35	
	8	32	31,1	
	9	10	9,7	
	10	2	1,9	
	Ukupno	103	100	
$\bar{X}$		7,0777		
Medijan		7,00		
Mod		7		
SD		1,56987		
Varijanca σ²		2,464		

Raspon		8
Σ		729
Skewness		-1,371
Kurtosis		2,415
Percentil	25	7
	50	7
	75	8



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 73. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 2 do 10. Dva su ispitanika (1,9%) dodijelila ocjenu 2, kao i što su 2 ispitanika (1,9%) dodijelila maksimalnu ocjenu 10. Histogram 20. predočava kako ocjene elementa interaktivne rezervacije restorana prate normalnu razdiobu. Uočljiva je koncentracija oko ocjena 7 i 8 (ukupno 66,1%). Mjera asimetrije normalne krivulje Skewness je umjerena i negativna -1,371 što ukazuje na umjeren pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 2,415 što označava vrlo umjerenu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 74. Bootstrap analiza ocjena elementa interaktivne rezervacije restorana

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	7,0777	0,0007	0,1528	6,767	7,3786
Medijan	7	0,075	0,2635	7	8
SD	1,56987	-0,01397	0,15992	1,23843	1,85904
Varijanca σ^2	2,464	-0,018	0,495	1,534	3,456
Skewness	-1,371	0,029	0,216	-1,755	-0,942
Kurtosis	2,415	0,024	1,025	0,754	4,786

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Ispitanici su element interaktivnu rezervaciju restorana ocijenili prosječnom ocjenom 7,0777 uz standardnu devijaciju od 1,56987 i varijancu 2,464. Bootstrap metoda s 95% povjerenja

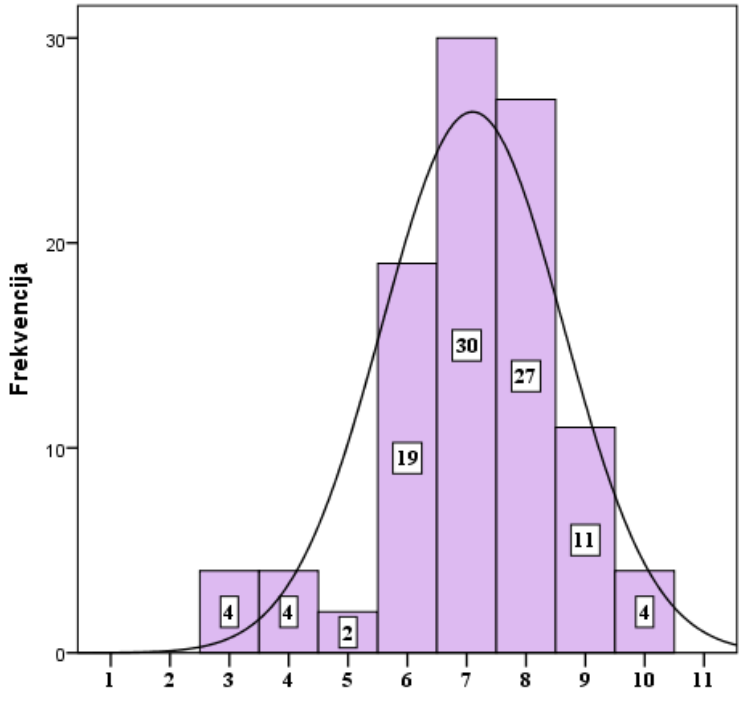
potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

1.29.3 Interaktivna rezervacija rekreativnih sadržaja

Interaktivna rezervacija rekreativnih sadržaja je mogućnost koja se pruža gostu da sam odredi vrijeme i mjesto gdje bi želio upražnjavati svoje aktivnosti što s druge strane omogućuje hotelu da rasporedi vrijeme korištenja terena, dvorana, bazena i organizira animatore, trenere i svu potrebnu logistiku. Interakcija se ogleda u tome da ako se zbog preopterećenja gostu ne može odobriti njegov termin, onda mu se može ponuditi prvi slobodan termin uz određeni popust ili sličan znak pažnje. Od ukupno 106 ispitanika njih 101 (95,3%) je dao svoje ocijene ovom elementu. Četvero ispitanika (4,7%) nije odgovorilo na postavljeno pitanja bez obrazloženja te se može pretpostaviti kako oni u svojem hotelu ne pružaju tu uslugu. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 75. Frekvencija i distribucija ocjena elementa interaktivne rezervacije rekreativnih sadržaja

Interaktivna rezervacija rekreativnih sadržaja		**F**	**%**	**Histogram ocjena elementa 21.**
	3	4	4	
	4	4	4	
	5	2	2	
	6	19	18,8	
	7	30	29,7	
	8	27	26,7	
	9	11	10,9	
	10	4	4	
	Ukupno	101	100	
$\bar{X}$		7,099		
Medijan		7,00		
Mod		7		
SD		1,52647		
Varijanca σ^2		2,330		
Raspon		7		
Σ		717		
Skewness		-0,704		
Kurtosis		0,838		
Percentil	25	6		
	50	7		
	75	8		



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 75. vidljivo je kako su ispitanici ocjenjivali ovaj element u rasponu ocjena od 3 do 10. Četiri ispitanika (4%) je dodijelio ocjenu 3, kao i što su četiri ispitanika (4%) dodijelila maksimalnu ocjenu 10. Histogram 21. predočava kako ocjene elementa interaktivne rezervacije rekreativnih sadržaja ne prate normalnu razdiobu. Uočljiva je koncentracija oko ocjena 7 i 8 (ukupno 56,4%). Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,704 što ukazuje na umjeren pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 0,838 što označava slabu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Narednom tablicom predočavaju se rezultati bootstrap metode za N = 1.000 s 95% povjerenja.

Tablica 76. Bootstrap analiza ocjena elementa interaktivne rezervacije rekreativnih sadržaja

Statistika		Bootstrap N = 1.000			
		Bias – sustavna pogreška	Standardna pogreška	95% Interval povjerenja	
				Donja granica	Gornja granica
$\bar{X}$	7,099	0,0021	0,1489	6,802	7,3861
Medijan	7	0,052	0,2221	7	8
SD	1,52647	-0,01377	0,12914	1,25715	1,76355
Varijanca σ^2	2,33	-0,025	0,39	1,58	3,11
Skewness	-0,704	0,04	0,205	-1,051	-0,255
Kurtosis	0,838	-0,043	0,486	-0,065	1,83

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

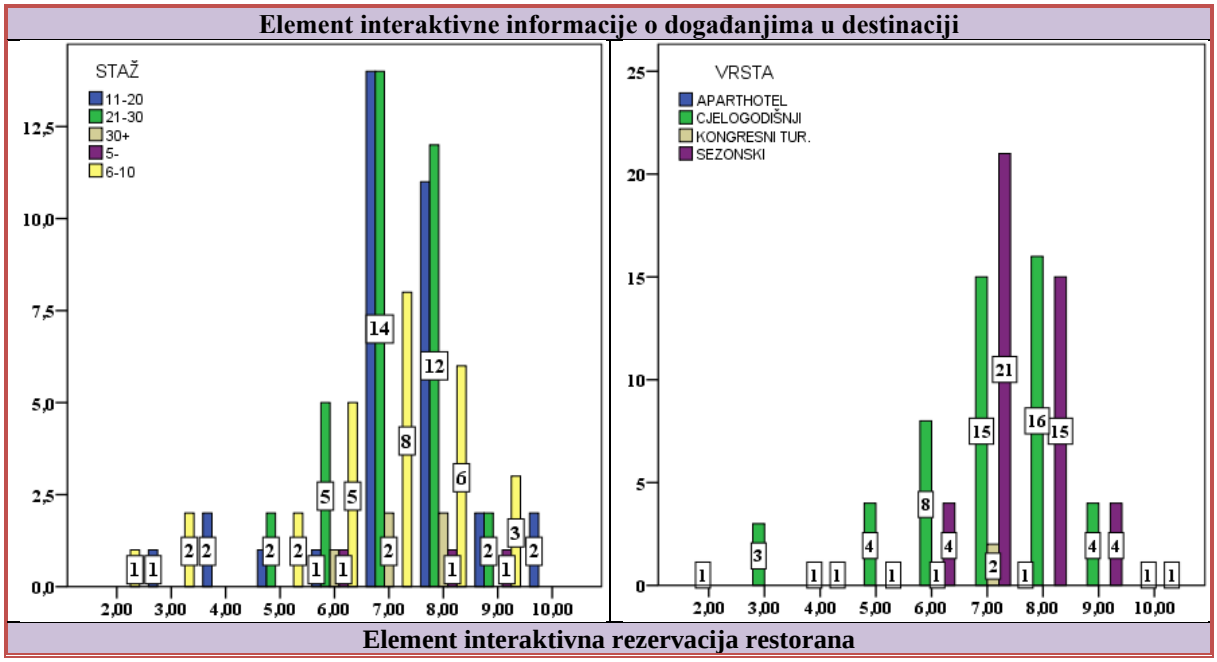
Ispitanici su element interaktivnu rezervaciju rekreativnih sadržaja ocijenili prosječnom ocjenom 7,099 uz standardnu devijaciju od 1,52647 i varijancu 2,33. Bootstrap metoda s 95% povjerenja potvrđuje relevantnost uzorka. Vrijednosti Biasa, odnosno sustavne pogreške koja može imati utjecaj na rezultat neznatne su.

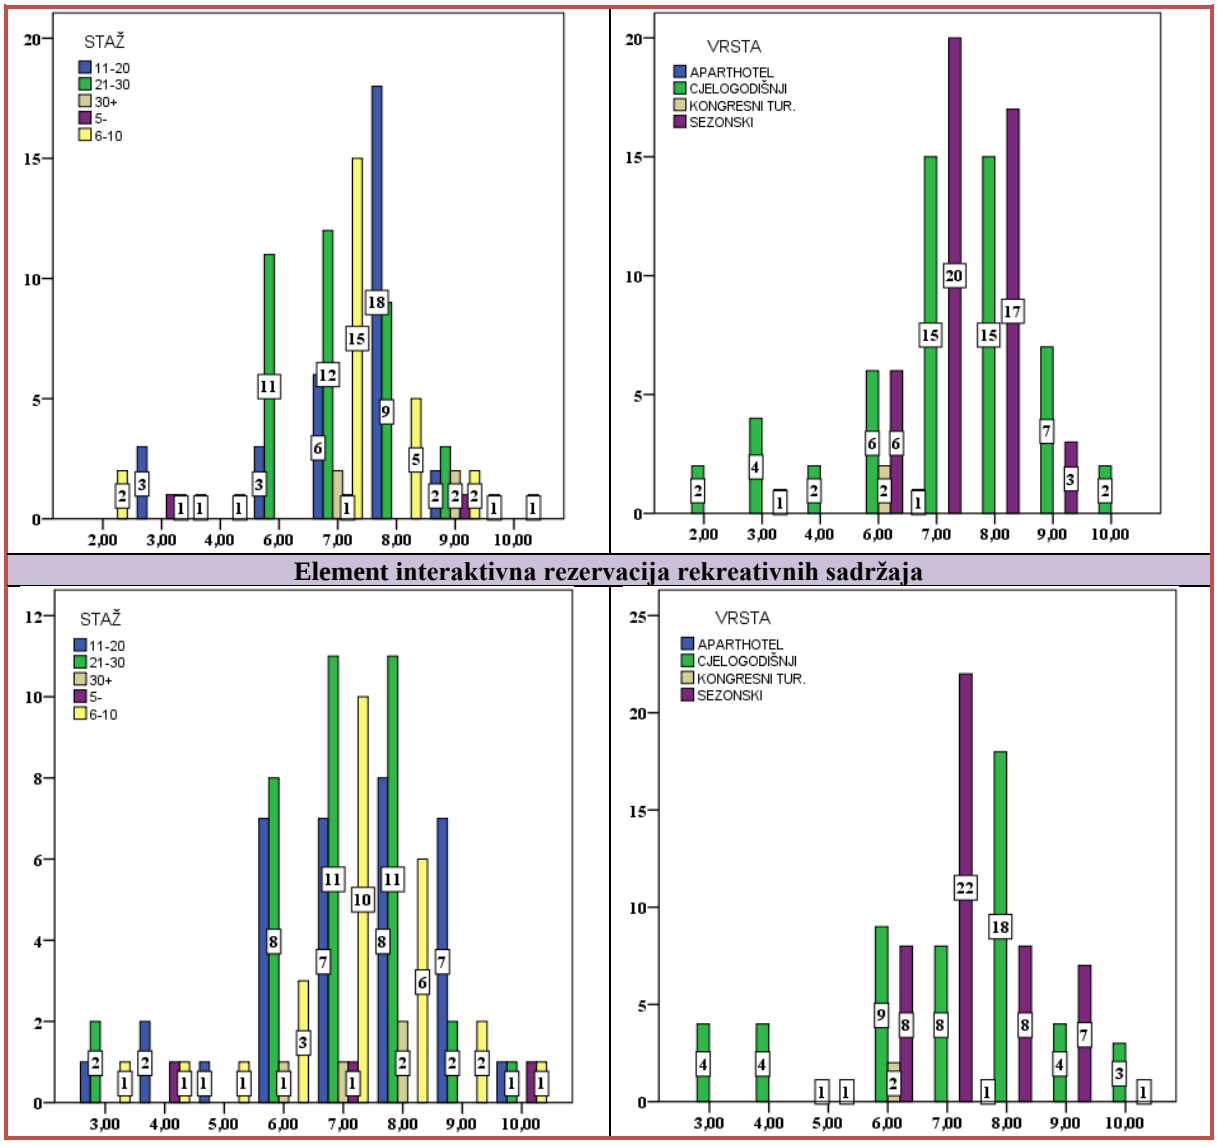
1.29.4 Analiza ostalih usluga u sklopu integriranih informacijsko-komunikacijskih usluga

Analogno dosad analiziranim elementima integriranih informacijsko-komunikacijskih usluga u hotelu analiziraju se i elementi ostalih usluga.

Analiza polazi od pretpostavke H_0 kako su ocjene ispitanika ravnomjerno distribuirane bez obzira na poziciju koju zauzima u hotelu. Nasuprot tome postavlja se hipoteza istraživanja H_I kojom se pretpostavlja da radni staž ispitanika i vrsta hotela utječu na stupanj ocjenjivanja internog oglašavanja integriranih informacijsko-komunikacijskih usluga u hotelu. Grafička analiza predočava se narednim složenim prikazom.

Grafikon 12. Grafička analiza elemenata ostalih usluga prema stažu ispitanika i vrsti hotela





Iz grafikona 12. vidljiva je distribucija dodijeljenih ocjena s obzirom na radni staž ispitanika i vrstu hotela, ali vizualno nije moguće ustanoviti njihovu ravnomjernost, a time i potvrđivanje/odbacivanje nul-hipoteze te je potrebno provesti dodatno χ^2 testiranje kako se to predočava narednim tablicama.

Tablica 77. χ^2 test značajnosti ocjena internog oglašavanja prema obrazovanju ispitanika

χ^2 test				
Ocjene elementa interaktivnih informacija o događanjima u destinaciji		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
2-10	Pearson χ^2	36,352	32	43,773
	Cramer's V	0,252		**$\chi^2 < \chi^2$ tablični prihvaća se H_0**
	Koeficijent kontingencije ***C***	0,450		
	Omjer izglednosti	28,935	32	
	N	104		
χ^2 test				

Ocjene elementa interaktivne rezervacije restorana		Vrijednost	df	Tablična vrijednost χ^2 za df i 5% sign.
2-10	Pearson χ^2	54,619	28	41,337
	Cramer's V	0,364		$\chi^2 > \chi^2$ tablični odbacuje se H_0
	Koeficijent kontingencije ***C***	0,589		
	Omjer izglednosti	54,722	28	
	N	103		
χ^2 test				
Ocjene elementa interaktivne rezervacije rekreativnih sadržaja		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
2-10	Pearson χ^2	27,829	28	41,337
	Cramer's V	0,262		$\chi^2 < \chi^2$ tablični prihvaća se H_0
	Koeficijent kontingencije ***C***	0,465		
	Omjer izglednosti	24,014	28	
	N	101		

Izvor: Izračun SPSS Statisticsa 21 temeljem podataka iz anketnog upitnika

Interpretacija dobivenih rezultata: radni staž ispitanika pokazao se kao faktor različitosti kada je u pitanju odnos prema ostalim elementima. Naime, hi kvadrat test pokazao je da se ravnomjernost distribucije ocjena postiže kod elemenata interaktivnih informacija o događanjima u destinaciji i interaktivne rezervacije rekreativnih sadržaja što znači da radno iskustvo ne utječe na ocjenjivanje tih dvaju elemenata što nije bio slučaj za element interaktivnu rezervaciju restorana gdje su stavovi prema radnom stažu došli do izražaja. Visoka vrijednost Cramerov V upućuje na asimetričnost ocjena, odnosno odstupanja od normalne razdiobe.

Tablica 78. χ^2 test značajnosti ocjena konferencijskih usluga prema veličini hotela

χ^2 test				
Ocjene elementa interaktivnih informacija o događanjima u destinaciji		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
2-10	Pearson χ^2	13,601	24	36,415
	Cramer's V	0,209		$\chi^2 < \chi^2$ tablični prihvaća se H_0
	Koeficijent kontingencije ***C***	0,340		
	Omjer izglednosti	13,295	24	
	N	104		
χ^2 test				
Ocjene elementa interaktivne rezervacije restorana		**Vrijednost**	**df**	**Tablična vrijednost χ^2 za df i 5% sign.**
2-10	Pearson χ^2	24,973	21	32,671
	Cramer's V	0,284		$\chi^2 < \chi^2$ tablični prihvaća se H_0
	Koeficijent kontingencije ***C***	0,442		
	Omjer izglednosti	22,698		
	N	103		
χ^2 test				

Ocjene elementa interaktivne rezervacije rekreativnih sadržaja		Vrijednost	df	Tablična vrijednost χ^2 za df i 5% sign.
2-10	Pearson χ^2	33,160	21	32,671
	Cramer's V	0,326		**$\chi^2 > \chi^2$ tablični odbacuje se H_0**
	Koeficijent kontingencije ***C***	0,491		
	Omjer izglednosti	33,089	21	
	N	101		

Izvor: Izračun SPSS Statisticsa 21 temeljem podataka iz anketnog upitnika

Interpretacija dobivenih rezultata: hi kvadrat test pokazuje da su tablične vrijednosti χ^2 za 5% statističke značajnosti veće od izračunatih kod elemenata interaktivnih informacija o događanjima u destinaciji i interaktivne rezervacije restorana što ukazuju na nezavisnost distribucije ocjena, odnosno kako vrsta hotela ne utječe na te elemente. Međutim pri testiranju elementa interaktivne rezervacije rekreativnih sadržaja gdje je **χ^2** izračunati > **χ^2** graničnog za 5% statističke značajnosti odbacuje *se* H_0 o nezavisnosti promatranih varijabli te se ujedno i prihvaća izglednost da vrsta hotela utječe na dodjeljivanje ocjena ostalih elemenata. Visoka vrijednost Cramerov V upućuje na asimetričnost ocjena, odnosno odstupanja od normalne razdiobe.

Daljnje istraživanje zakonitosti utjecaja osobnih stavova ispitanika odnosi se na lokaciju hotela kao faktora različitosti s obzirom na zemljopisne posebnosti Republike Hrvatske. U tom kontekstu provodi se analiza ANOVA za prethodno elaborirane elemente ostalih usluga. Postavlja se hipoteza istraživanja H_I kako lokacija ispitanikovih hotela utječe na distribuciju ocjena ostalih usluga.

Kako su ispitanici dodjeljivali svoje ocjene pojedinim elementima ostalih usluga i kakva je njihova međusobna povezanost u odnosu na ispitanikovu lokaciju, predočava se narednom tablicom.

Tablica 79. Analiza varijanci ocjena ostalih usluga prema lokaciji ispitanikova hotela

Lokacija hotela		Interaktivne informacije o događanjima u destinaciji	Interaktivna rezervacija restorana	Interaktivna rezervacija rekreativnih sadržaja
Kontinent	$\bar{X}$	6,5455	6,4242	6,9375
	% od N	31,7%	32,0%	31,7%
Otoci	$\bar{X}$	7,5000	7,3125	7,2500
	% od N	15,4%	15,5%	15,8%
Priobalje	$\bar{X}$	7,2973	7,3889	7,5278
	% od N	35,6%	35,0%	35,6%
Urbani	$\bar{X}$	7,2222	7,4444	6,3529
	% od N	17,3%	17,5%	16,8%

ANOVA	Zbroj kvadrata	df	Srednji kvadrati	F	F granični za 5% sign.

Interaktivna rezervacija rekreativnih sadržaja * lokacija hotela	Između grupa	14,362	3	4,787	**2,506**	3;103
	Unutar grupe	191,023	100	1,910		**2,70**
	Ukupno	205,385	103			
Interaktivna rezervacija restorana * lokacija hotela	Između grupa	20,881	3	6,960	**2,989**	3;99
	Unutar grupe	230,498	99	2,328		**2,70**
	Ukupno	251,379	102			
Interaktivna rezervacija rekreativnih sadržaja * lokacija hotela	Između grupa	17,280	3	5,760	**2,590**	3;97
	Unutar grupe	215,730	97	2,224		**2,70**
	Ukupno	233,010	100			

Izvor: Izračun SPSS Statisticsa 24 temeljem podataka iz anketnog upitnika

Interpretacija: kako je vidljivo iz ANOVA tablice 59., vrijednosti F izračunato manje su od F tablično za 5% statističke značajnosti za elemente interaktivnu rezervaciju rekreativnih sadržaja i interaktivnu rezervaciju rekreativnih sadržaja što u tim slučajevima potvrđuje nul-hipotezu o ravnomjernosti distribucije ocjene neovisno o lokaciji na kojoj se hotel nalazi. Nasuprot tome kod elementa interaktivne rezervacije restorana uočljiva je zavisnost ocjenjivanja o lokaciji hotela ispitanika te se odbacuje nul-hipoteza i prihvaća hipoteza istraživanja H_I.

Shodno detektiranim različitostima koje se uočavaju pri interpretaciji rezultata pristupa se analizi korelacije srednjih vrijednosti ocjena promatranih elemenata ostalih usluga u hotelu.

Tablica 80. Korelacija prosječnih ocjena elemenata ostalih usluga

		Elementi ostalih usluga		
Funkcija	**Elementi ostalih usluga**	1	2	3
1	Interaktivna rezervacija rekreativnih sadržaja	1	0,794	0,583
2	Interaktivna rezervacija restorana	0,794	1	0,655
3	Interaktivna rezervacija rekreativnih sadržaja	0,583	0,655	1

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Korelacija je računata Pearsonovim koeficijentom korelacije kojim se prepoznaje povezanost ako je koeficijent veći od 0,5. Ovime je potvrđena relevantnost poznavatelja s obzirom na to da su elementi usluga internog oglašavanja kreirani na način da djeluju koordinirano.

1.30 Ocjene funkcija sustava CRM-a

Ispitanicima su ponuđene na ocjenjivanje sljedeće funkcije CRM-a: 1) unaprjeđenje usmjerenosti gostiju prema potrošnji, 2) unaprjeđenje kvalitete pružene usluge, 3) unaprjeđenje lojalnosti gostiju, 4) unaprjeđenje konkurentnosti hotela te 5) upravljanje bazom gostiju i neposredno dobivanje povratnih informacija.

1.30.1 Unaprjeđenje usmjerenosti gostiju prema potrošnji

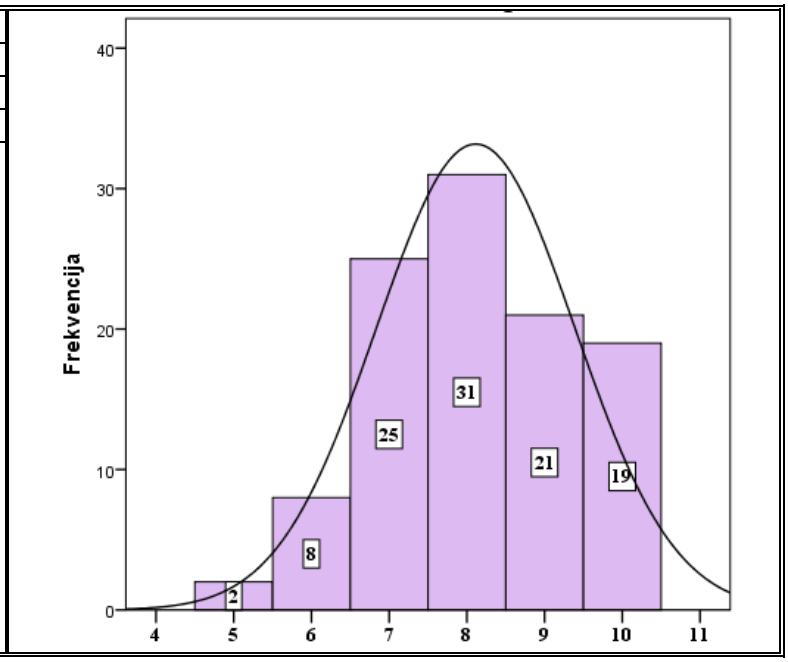
Samo korisnici i/ili dobri poznavatelji funkcija CRM-a mogu argumentirano donijeti svoj sud o funkcijama CRM-a.

Svi su ispitanici (100%) ocijenili funkciju CRM-a unaprjeđenje usmjerenosti gostiju prema potrošnji. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 81. Frekvencija i distribucija ocjena funkcije CRM-a unaprjeđenje usmjerenosti gostiju prema potrošnji

Unaprjeđenje usmjerenosti gostiju prema potrošnji		F	%	Histogram ocjena funkcije 1.
	5	2	1,9	
	6	8	7,5	
	7	25	23,6	
	8	31	29,2	
	9	21	19,8	
	10	19	17,9	
	Ukupno	106	100	
$\bar{X}$		8,1132		
Medijan		8,00		
Mod		8		
SD		1,27482		
Varijanca σ^2		1,625		
Raspon		5		
Σ		860		

Skewness		-0,132
Kurtosis		0,465
Percentil	25	7
	50	8
	75	9



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

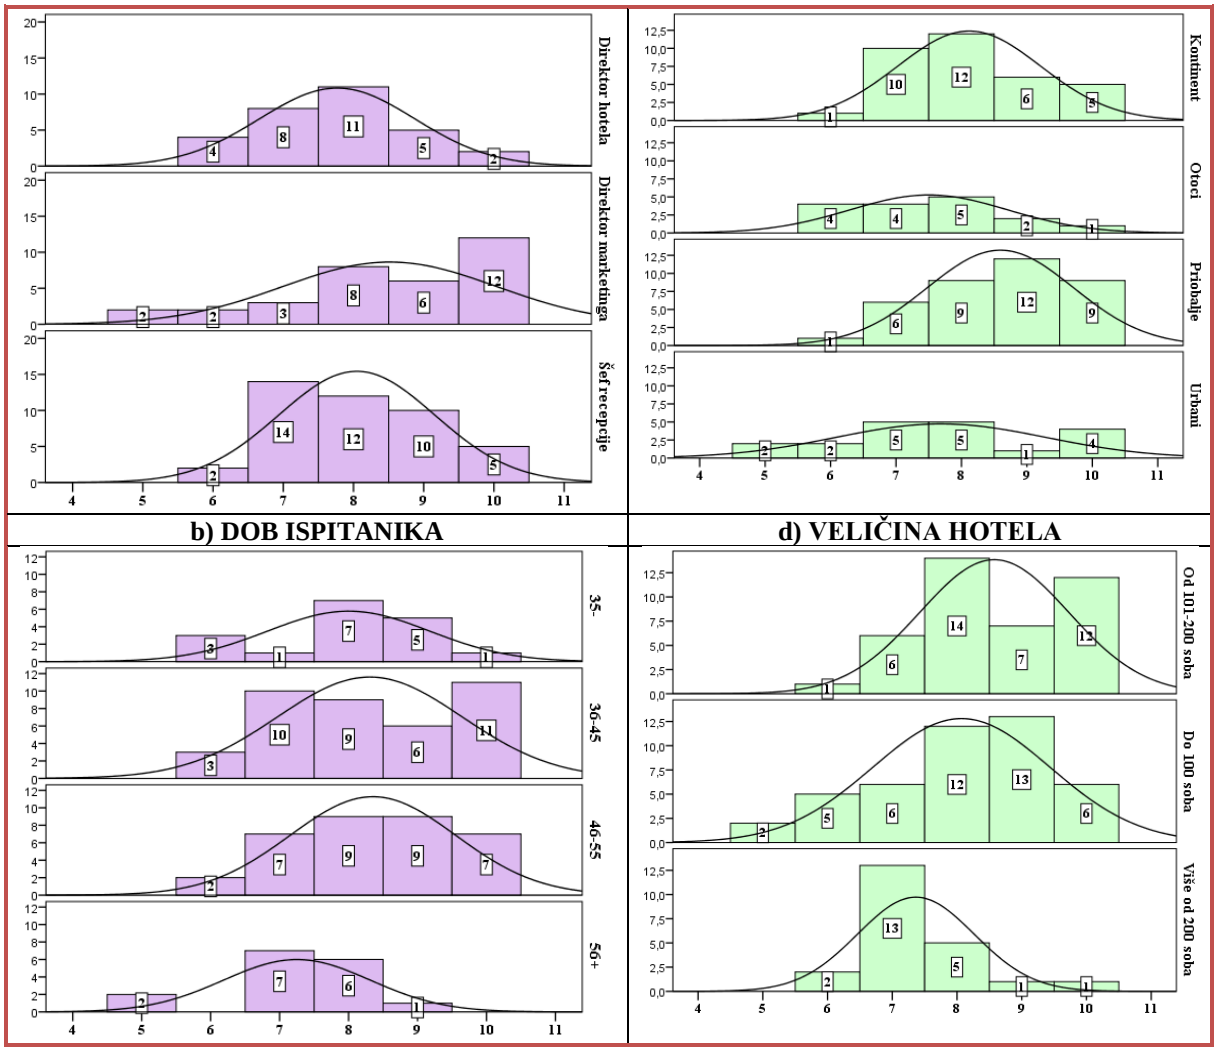
Iz tablice 81. vidljivo je kako su ispitanici ocjenjivali ovu funkciju u rasponu ocjena od 5 do 10. Dva su ispitanika (1,9%) dodijelila ocjenu 5 dok je 19 ispitanika (17,8%) dodijelilo maksimalnu ocjenu 10. Ocjena 8 je istaknuta (29,2%). Priloženi histogram jasno predočava kako ocjene funkcije CRM-a unaprjeđenje usmjerenosti gostiju prema potrošnji prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,132 što ukazuje na vrlo slab pomak prema većim ocjenama.

Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 0,465 što označava slabu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Ispitanici su promatranu funkciju CRM-a ocijenili prosječnom ocjenom 8,1132 uz standardnu devijaciju od 1,24782 i varijancu 1,625. Narednim grafičkim prikazom predočava se kako su ispitanici ocjenjivali promatranu funkciju CRM-a sa stajališta pozicije i dobi te lokacije i veličine anketom obuhvaćenih hotela.

Distribucija ocjena funkcije unaprjeđenja usmjerenosti gostiju prema potrošnji prema: a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela predočava se narednim složenim grafičkim prikazom.

Grafikon 13. Distribucija ocjena funkcije unaprjeđenja usmjerenosti gostiju prema potrošnji prema: a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela

a) POZICIJA ISPITANIKA	c) LOKACIJA HOTELA



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

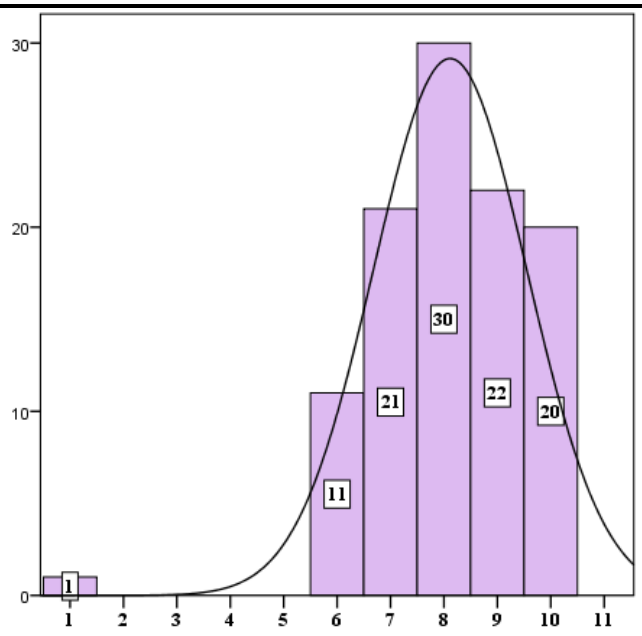
Iz grafikona 13. vidljivo je kako su distribuirane ocjene s obzirom na normalnu krivulju. Sa stajališta pozicije najbolje su prosječne ocjene dodijelili direktori marketinga (8,5) a potom šefovi recepcija (8,1) i glavni direktori (7,8). Prema starosnoj dobi najbolje prosječne ocjene dodijelili su ispitanici iz skupine 46 – 55 godina (8,4) a najslabije (7,3) iz skupine „više od 56 godina“. Prema lokaciji hotela najbolje prosječne ocjene bile su u priobalju (8,6) a najslabije na otocima (7,5). Prema veličini hotela najbolje su ocjene dali ispitanici manjih hotela (8,1) dok su najslabije ocjene došle iz velikih hotela (7,4).

1.30.2 Unaprjeđenje kvalitete pružene usluge

Unaprjeđenje kvalitete pružene usluge jedna je od funkcija CRM-a koja je prvenstveno usmjerena prema davatelju usluge, odnosno hotelu. Koliko i u kojoj mjeri je CRM zaslužan za unaprjeđenje kvalitete pružene usluge, ocjenjivali su ispitanici.

Od 106 ispitanika njih 105 (99,1%) ocijenili su funkciju CRM-a unaprjeđenje kvalitete pružene usluge dok jedan ispitanik (0,9%) nije dao nikakav odgovor. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 82. Frekvencija i distribucija ocjena funkcije CRM-a unaprjeđenje kvalitete usluge

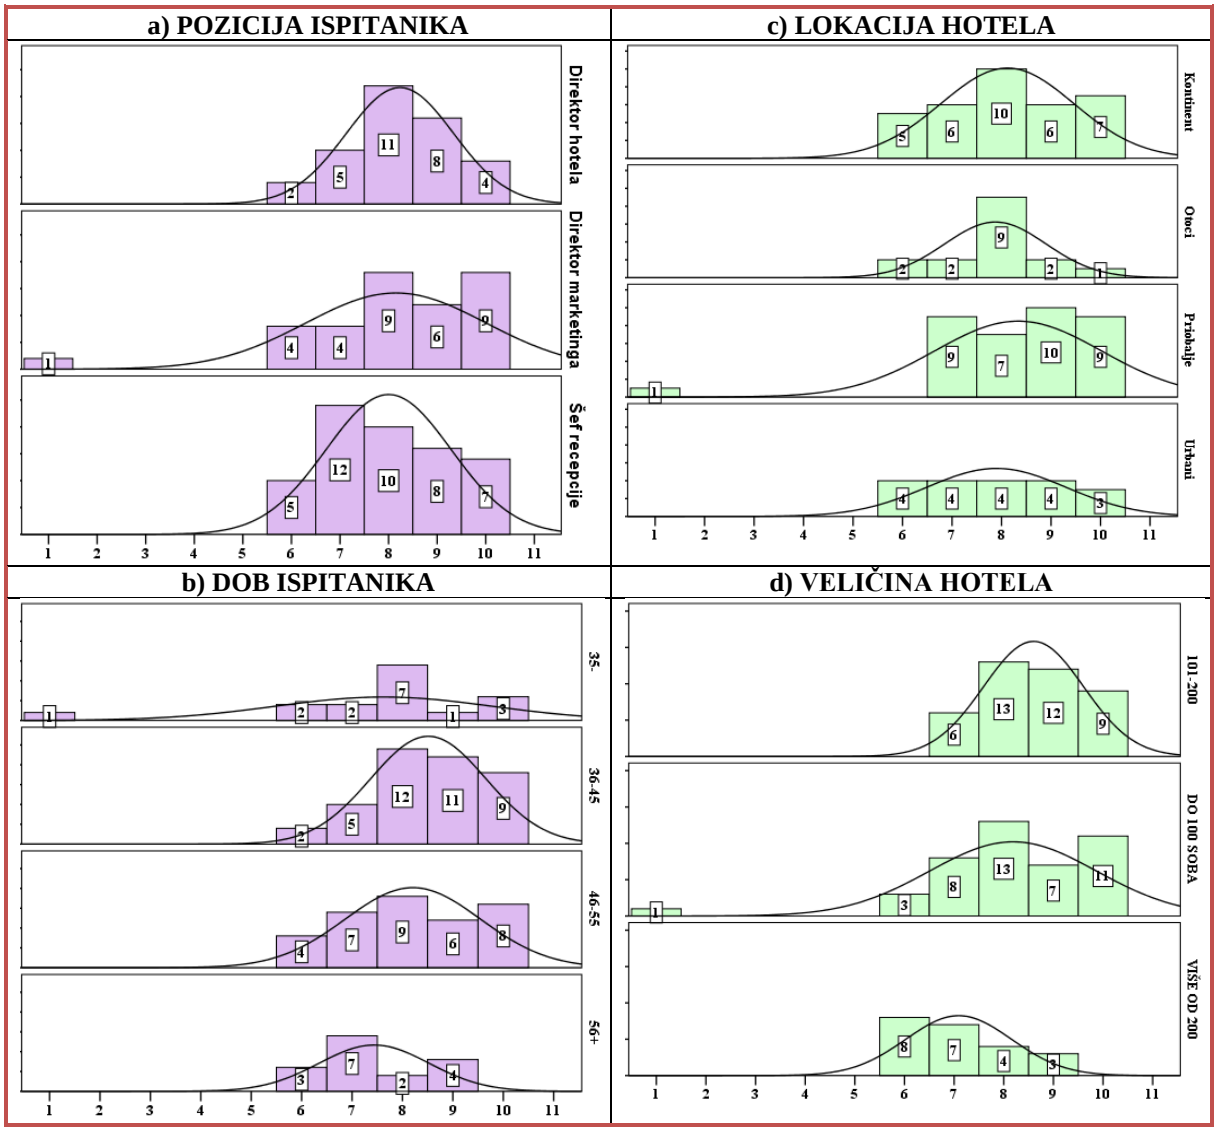
Unaprjeđenje kvalitete usluge		**F**	**%**	**Histogram ocjena funkcije 2.**
	1	1	1	
	6	11	10,5	
	7	21	20	
	8	30	28,6	
	9	22	21	
	10	20	19	
	Ukupno	105	100	
$\bar{X}$		8,1143		
Medijan		8,00		
Mod		8		
SD		1,43657		
Varijanca σ^2		2,064		
Raspon		9		
Σ		852		
Skewness		-1,137		
Kurtosis		4,279		
Percentil	25	7		
	50	8		
	75	9		

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 48. vidljivo je kako su ispitanici ocjenjivali ovu funkciju u rasponu ocjena od 1 do 10. Jedan je ispitanik (1,0%) dodijelio ocjenu 1 dok je 20 ispitanika (19,0%) dodijelilo maksimalnu ocjenu 10. Ocjena 8 je istaknuta (28,6%). Priloženi histogram jasno predočava kako ocjene funkcije CRM-a unaprjeđenje kvalitete pružene usluge prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je izražena i negativna -1,137 što ukazuje na izražen pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 4,279 što označava izraženu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Ispitanici su promatranu funkciju CRM-a ocijenili prosječnom ocjenom 8,1143 uz standardnu devijaciju od 1,43657 i varijancu 2,064. Narednim grafičkim prikazom predočava se kako su ispitanici ocjenjivali promatranu funkciju CRM-a sa stajališta pozicije i dobi te lokacije i veličine anketom obuhvaćenih hotela.

Distribucija ocjena funkcije unaprjeđenja kvalitete usluge prema: a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela predočava se narednim složenim grafičkim prikazom.

Grafikon 14. Distribucija ocjena funkcije unaprjeđenja kvalitete usluge prema: a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz grafikona 14. vidljivo je kako su distribuirane ocjene s obzirom na normalnu krivulju. Sa stajališta pozicije u hotelu najbolje su prosječne ocjene dodijelili direktori hotela (8,2) a potom direktori marketinga (8,15) te šefovi recepcija (8,0). Promatrano prema starosnoj dobi najbolje prosječne ocjene dodijelili su ispitanici iz skupine 36 – 45 godina (8,5), a najslabije (7,6) iz skupine do 35 godina. Prema lokaciji hotela najbolje prosječne ocjene bile su u priobalju (8,3),

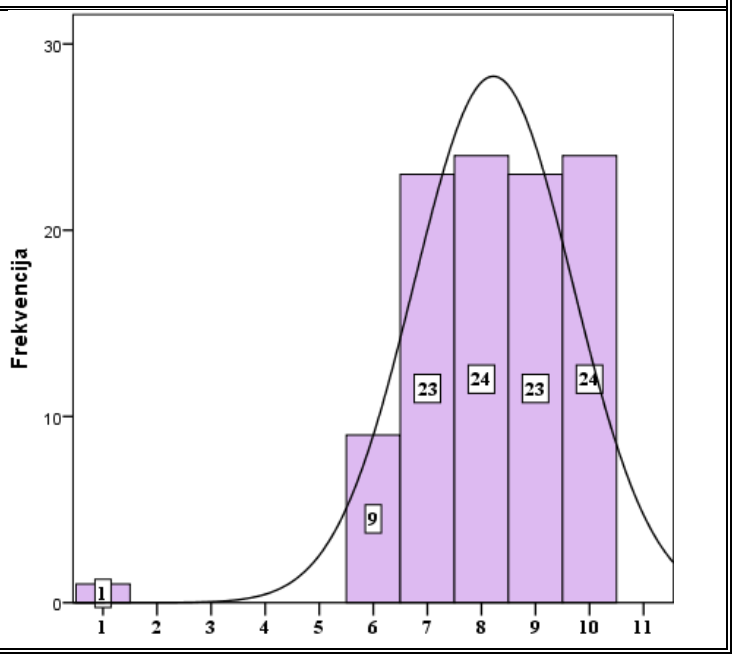
a najslabije na otocima (7,87). Prema veličini hotela najbolje su ocjene dali ispitanici manjih hotela (8,6) dok su najslabije ocjene došle iz velikih hotela (7,09).

1.30.3 Unaprjeđenje lojalnosti gostiju

CRM je upravo i osmišljen kako bi poticao unaprjeđenje lojalnosti gostiju te je očekivano i funkcija koja se najviše i najčešće propituje. Od 106 ispitanika njih 104 (98,1%) ocijenili su funkciju CRM-a unaprjeđenje kvalitete pružene usluge dok dvoje ispitanika (1,9%) nije dalo nikakav odgovor. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 83. Frekvencija i distribucija ocjena funkcije CRM-a unaprjeđenje lojalnosti gostiju

Unaprjeđenje lojalnosti gostiju		**F**	**%**	**Histogram ocjena funkcije 3.**
	1	1	1	
	6	9	8,7	
	7	23	22,1	
	8	24	23,1	
	9	23	22,1	
	10	24	23,1	
	Ukupno	104	100	
$\bar{X}$		8,2212		
Medijan		8,000		
Mod		8		
SD		1,16782		
Varijanca σ^2		2,154		
Raspon		9		
Σ		855		
Skewness		-1,162		
Kurtosis		4,090		
Percentil	25	7		
	50	8		
	75	9		



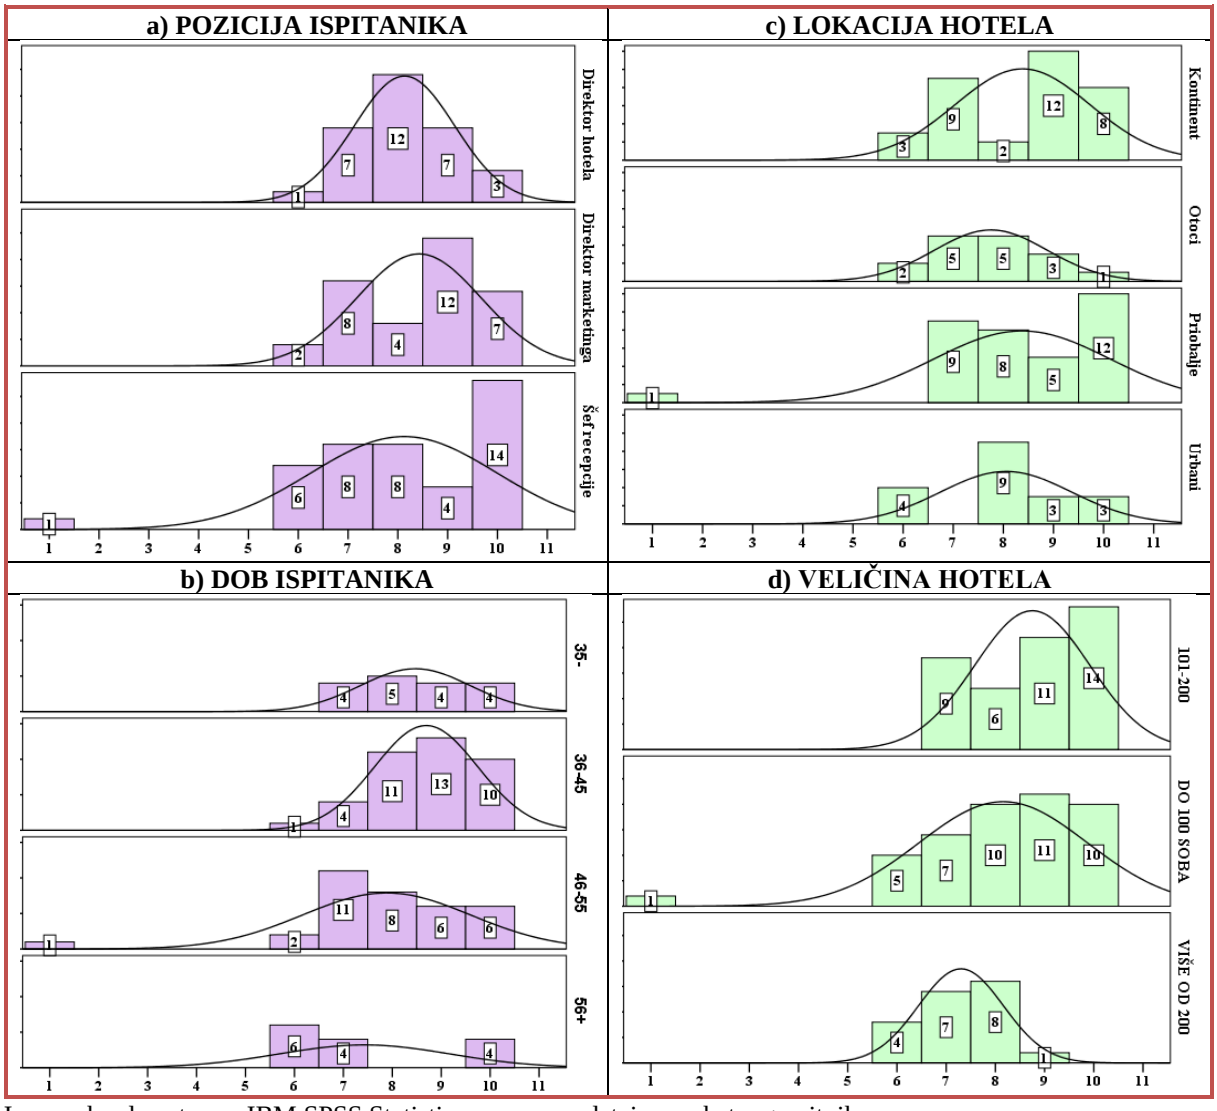
Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 83. vidljivo je kako su ispitanici ocjenjivali ovu funkciju u rasponu ocjena od 1 do 10. Jedan je ispitanik (1,0%) dodijelio ocjenu 1 dok je 24 ispitanika (23,1%) dodijelilo maksimalnu ocjenu 10. Podjednako su raspoređene ocjene 7, 8, 9 i 10 koje ukupno čine 90,4% svih ocjena. Priloženi histogram jasno predočava kako ocjene funkcije CRM-a unaprjeđenje lojalnosti gostiju ne prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je izražena i negativna -1,162 što ukazuje na izražen pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 4,090 što označava izraženu

leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Ispitanici su promatranu funkciju CRM-a ocijenili prosječnom ocjenom 8,2212 uz standardnu devijaciju od 1,1678 i varijancu 2,154. Narednim grafičkim prikazom predočava se kako su ispitanici ocjenjivali promatranu funkciju CRM-a sa stajališta pozicije i dobi te lokacije i veličine anketom obuhvaćenih hotela.

Distribucija ocjena funkcije unaprjeđenja lojalnosti gostiju prema: a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela predočava se narednim grafičkim prikazom.

Grafikon 15. Distribucija ocjena funkcije unaprjeđenja lojalnosti gostiju prema: a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz grafikona 15. vidljivo je kako su distribuirane ocjene s obzirom na normalnu krivulju. Sa stajališta pozicije u hotelu najbolje su prosječne ocjene dodijelili direktori marketinga (8,4), a

potom direktori hotela (8,13) te šefovi recepcija (8,12). Promatrano prema starosnoj dobi najbolje su prosječne ocjene dodijelili ispitanici iz skupine 36 – 45 godina (8,69), a najslabije (7,4) iz skupne „više od 56 godina“. Prema lokaciji hotela najbolje prosječne ocjene bile su na kontinentu i priobalju (8,4), a najslabije na otocima (7,75). Prema veličini hotela najbolje su ocjene dali ispitanici manjih hotela (8,75) dok su najslabije ocjene došle iz velikih hotela (7,3).

1.30.4 Unaprjeđenje konkurentnosti hotela

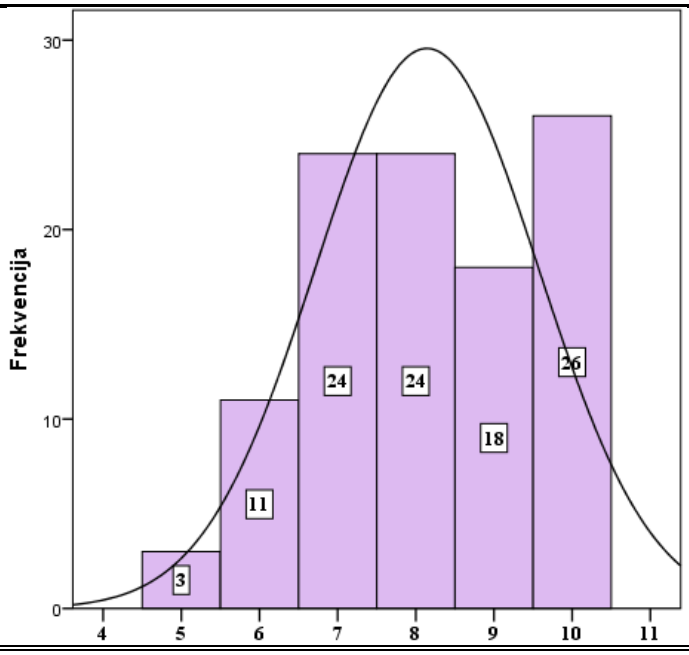
Unaprjeđenje konkurentnosti hotela je funkcija CRM-a koja je prvenstveno usmjerena prema davatelju usluge, odnosno hotelu. Koliko i u kojoj mjeri je CRM zaslužan za unaprjeđenje konkurentnosti hotela ocjenjivali su ispitanici.

Svih 106 ispitanika (100%) ocijenilo je funkciju CRM-a unaprjeđenje konkurentnosti hotela. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 84. Frekvencija i distribucija ocjena funkcije CRM-a unaprjeđenje konkurentnosti hotela

Unaprjeđenje konkurentnosti hotela		**F**	**%**
	5	3	2,8
	6	11	10,4
	7	24	22,6
	8	24	22,6
	9	18	17
	10	26	24,5
	Ukupno	106	100
$\bar{X}$		8,1415	
Medijan		8	
Mod		10	
SD		1,43054	
Varijanca σ^2		2,046	
Raspon		5	
Σ		863	
Skewness		-0,194	
Kurtosis		-0,958	
Percentil	25	7	
	50	8	
	75	9,25	

Histogram ocjena funkcije 4.

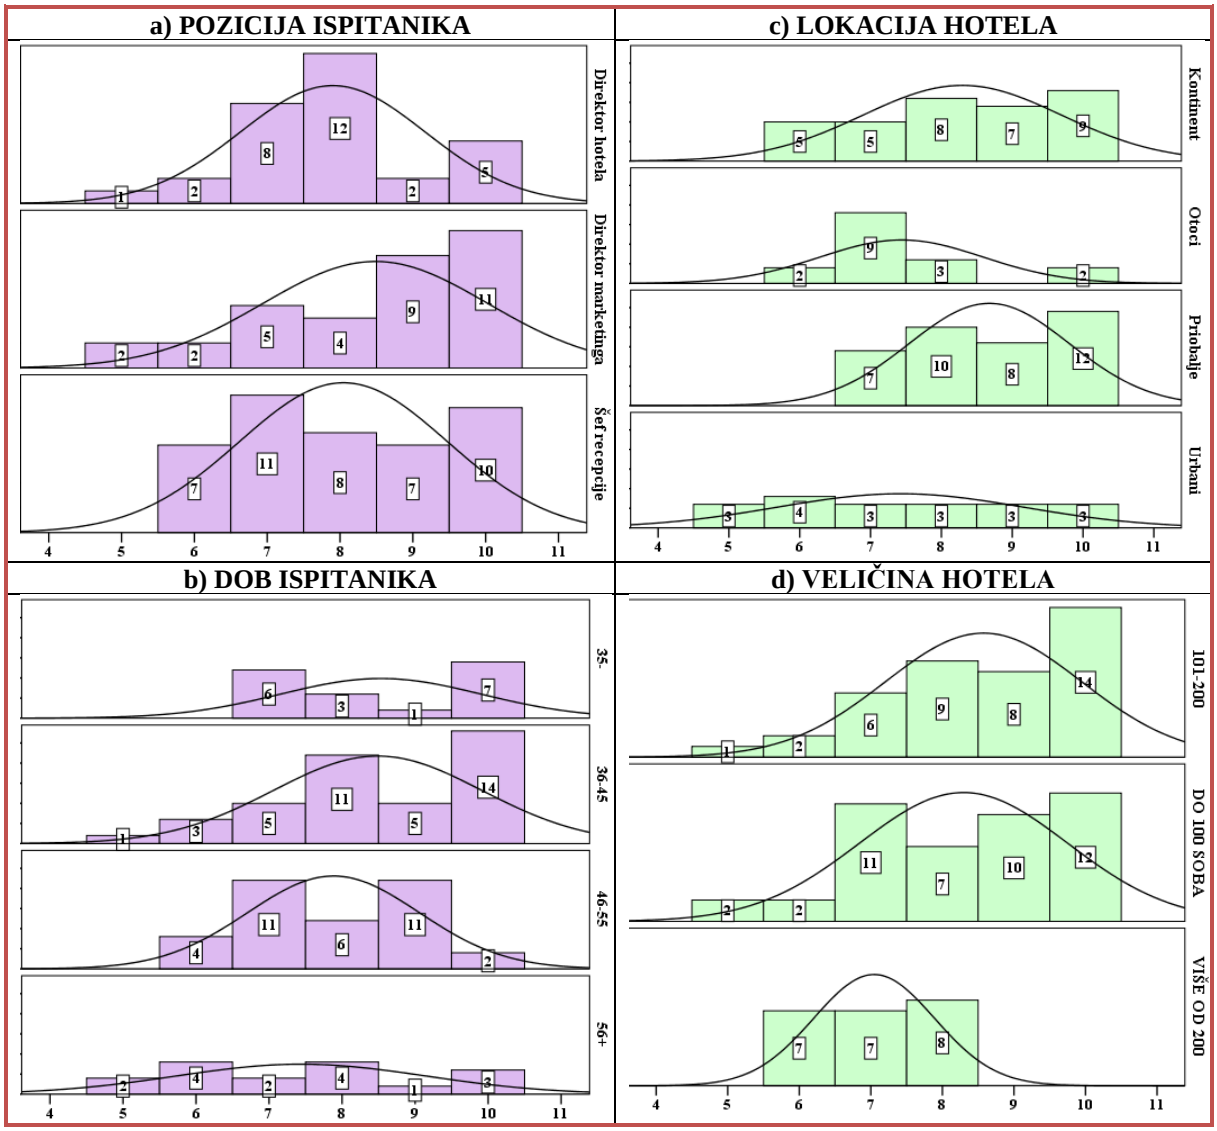


Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 84. vidljivo je kako su ispitanici ocjenjivali ovu funkciju u rasponu ocjena od 5 do 10. Tri su ispitanika (2,8%) dodijelila ocjenu 5 dok je 26 ispitanika (24,5%) dodijelilo maksimalnu ocjenu 10. Ocjene 7 i 8 su istaknute (ukupno 45,2%). Priloženi histogram jasno

predočava kako ocjene funkcije CRM-a unaprjeđenje konkurentnosti hotela prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,194 što ukazuje na slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -0,958 što označava umjerenu platikurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Ispitanici su promatranu funkciju CRM-a ocijenili prosječnom ocjenom 8,1415 uz standardnu devijaciju od 1,43054 i varijancu 2,064. Narednim grafičkim prikazom predočava se kako su ispitanici ocjenjivali promatranu funkciju CRM-a sa stajališta pozicije i dobi te lokacije i veličine anketom obuhvaćenih hotela.

Grafikon 16. Distribucija ocjena funkcije unaprjeđenja konkurentnosti hotela prema: a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz grafikona 16. vidljivo je kako su distribuirane ocjene s obzirom na normalnu krivulju. Sa stajališta pozicije u hotelu najbolje su prosječne ocjene dodijelili direktori marketinga (8,48), a

potom šefovi recepcija (8,0) te direktori hotela (7,9). Promatrano prema starosnoj dobi najbolje prosječne ocjene dodijelili su ispitanici iz najmlađe skupine do 35 godina (8,5), a najslabije (7,4) iz najstarije skupne „više od 56 godina“. Prema lokaciji hotela najbolje prosječne ocjene bile su u priobalju (8,67), a najslabije u gradskim hotelima (7,42). Prema veličini hotela najbolje su ocjene dali ispitanici manjih hotela (8,57) dok su najslabije ocjene došle iz velikih hotela (7,04).

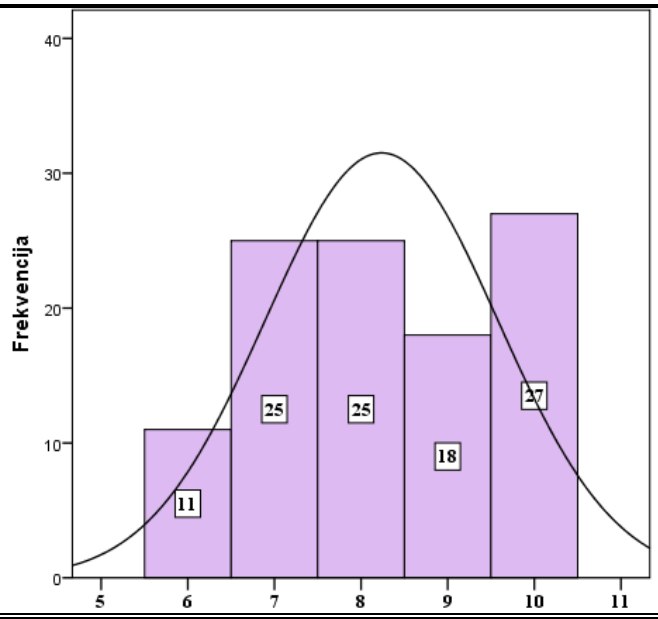
1.30.5 Upravljanje podatkovnom bazom gostiju

Upravljanje podatkovnom bazom gostiju i neposredno dobivanje povratnih informacija je funkcija CRM-a na kojoj se temelje sve daljnje marketinške aktivnosti. Kvalitetna podatkovna baza i odgovarajuća softverska aplikacija jamac su uspjeha implementacije CRM-a u hotel.

Svih 106 ispitanika (100%) ocijenilo je funkciju CRM-a unaprjeđenje konkurentnosti hotela. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 85. Frekvencija i distribucija ocjena funkcije CRM-a upravljanje podatkovnom bazom gostiju

Upravljanje podatkovnom bazom gostiju		**F**	**%**	**Histogram ocjena funkcije 5.**
	6	11	10,4	
	7	25	23,6	
	8	25	23,6	
	9	18	17	
	10	27	25,5	
	Ukupno	106	100	
$\bar{X}$		8,2358		
Medijan		8,00		
Mod		10		
SD		1,34201		
Varijanca σ^2		1,801		
Raspon		4		
Σ		873		
Skewness		-0,057		
Kurtosis		-1,219		
Percentil	25	7		
	50	8		
	75	10		

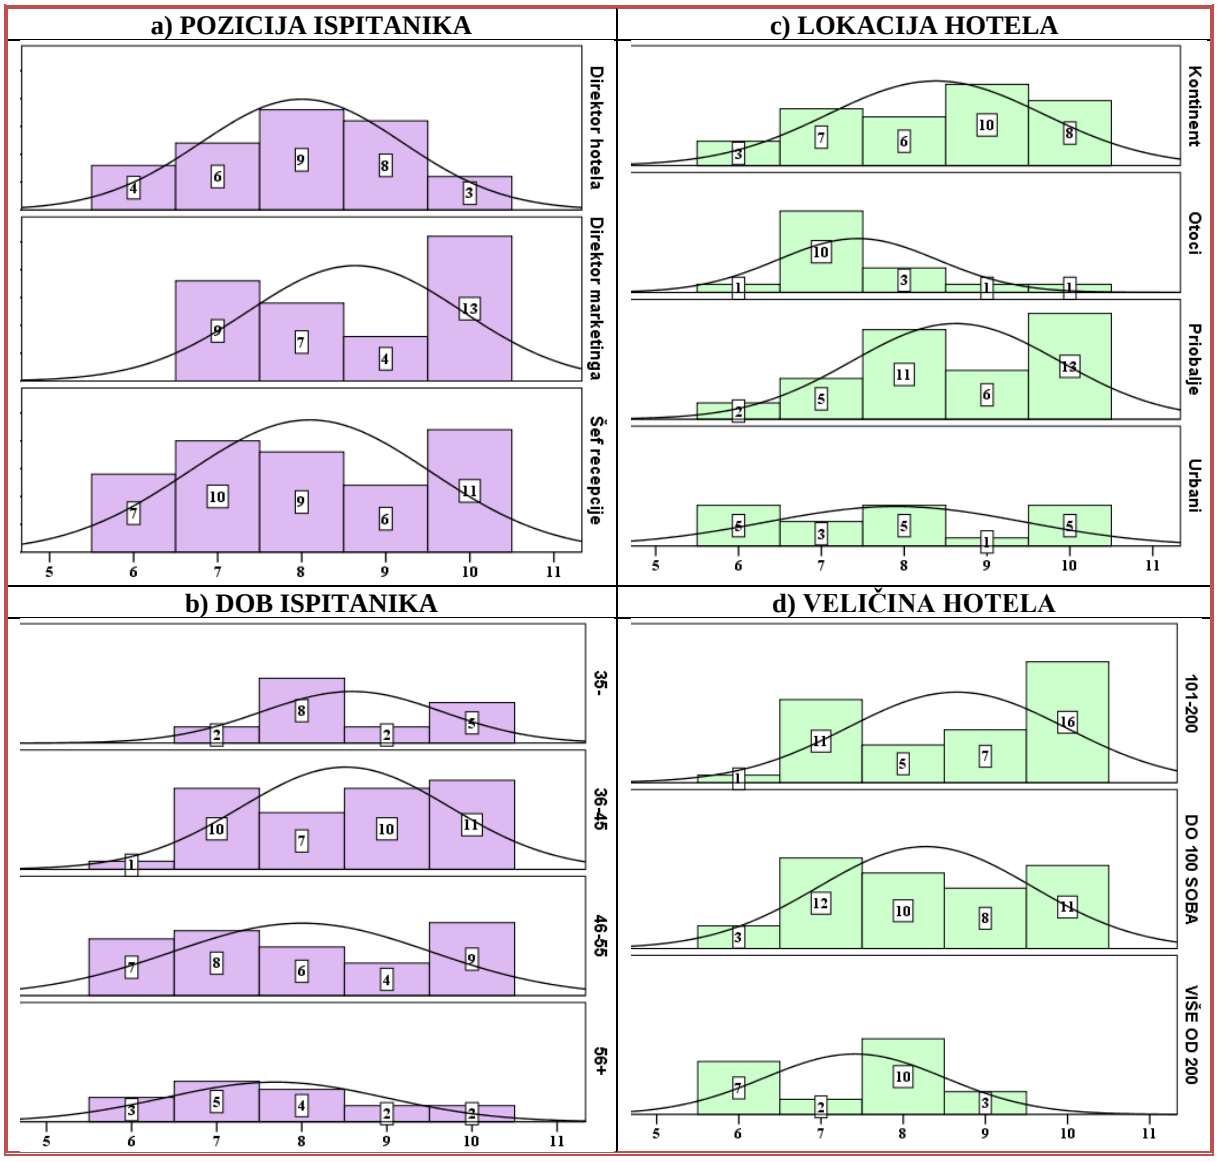


Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 85. vidljivo je kako su ispitanici ocjenjivali ovu funkciju u rasponu ocjena od 6 do 10. Jedanaest je ispitanika (10,4%) dodijelio ocjenu 6 dok je 27 ispitanika (25,5%) dodijelilo maksimalnu ocjenu 10. Ocjene 7 i 8 su istaknute (ukupno 47,2%). Priloženi histogram jasno predočava kako ocjene funkcije CRM-a upravljanje podatkovnom bazom gostiju prate

normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je vrlo slaba i negativna – 0,057 što ukazuje na slab pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -1,219 što označava umjerenu platikurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Ispitanici su promatranu funkciju CRM-a ocijenili prosječnom ocjenom 8,2358 uz standardnu devijaciju od 1,34201 i varijancu 1,801. Narednim grafičkim prikazom predočava se kako su ispitanici ocjenjivali promatranu funkciju CRM-a sa stajališta pozicije i dobi te lokacije i veličine anketom obuhvaćenih hotela.

Grafikon 17. Distribucija ocjena funkcije upravljanja podatkovnom bazom gostiju prema: a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz grafikona 17. vidljivo je kako su distribuirane ocjene s obzirom na normalnu krivulju. Sa stajališta pozicije u hotelu najbolje su prosječne ocjene dodijelili direktori marketinga (8,64), a potom šefovi recepcija (8,09) te direktori hotela (8,0).

Promatrano prema starosnoj dobi najbolje su prosječne ocjene dodijelili ispitanici iz najmlađe skupine do 35 godina (8,58), a najslabije (7,68) iz najstarije skupne „više od 56 godina“. Prema lokaciji hotela najbolje prosječne ocjene bile su u priobalju (8,62), a najslabije na otocima (7,44). Prema veličini hotela najbolje su ocjene dali ispitanici manjih hotela (8,65) dok su najslabije ocjene došle iz velikih hotela (7,41).

1.30.6 Analiza funkcija sustava CRM-a

Analogno dosad analiziranim elementima integriranih informacijsko-komunikacijskih usluga u hotelu analiziraju se i funkcije sustava CRM-a. Kao metode kojom se istražuju povezanosti između pojedinih varijabli (funkcija) koristi se analiza varijance ANOVA. Istražit će se povezanost prema obrazovanju ispitanika i vrsti hotela.

Postavlja se hipoteza istraživanja H_I kako stupanj obrazovanja ispitanika utječe na distribuciju ocjena funkcija CRM-a. Kako su ispitanici dodjeljivali svoje ocjene pojedinim funkcijama i kakva je njihova međusobna povezanost u odnosu na ispitanikovo obrazovanje, predočava se narednom tablicom.

Tablica 86. Analiza varijanci ocjena funkcija CRM-a prema stupnju obrazovanja ispitanika

Obrazovanje ispitanika		Unaprjeđenje usmjerenosti gostiju prema potrošnji	Unaprjeđenje kvalitete usluge	Unaprjeđenje lojalnosti gostiju	Unaprjeđenje konkurentnosti hotela	Upravljanje podatkovnom bazom gostiju
Mr/Dr	$\bar{X}$	7,3125	7,6250	7,8750	7,7500	8,0625
	% od N	15,1%	15,2%	15,4%	15,1%	15,1%
VSS	$\bar{X}$	8,4118	8,3200	8,3529	8,2549	8,3725
	% od N	48,1%	47,6%	49,0%	48,1%	48,1%
VŠS	$\bar{X}$	8,0513	8,0513	8,1892	8,1538	8,1282
	% od N	36,8%	37,1%	35,6%	36,8%	36,8%

ANOVA		Zbroj kvadrata	df	Srednji kvadrati	F	F granični za 5% sign.
Unaprjeđenje usmjerenosti gostiju prema potrošnji * obrazovanje ispitanika	Između grupa	14,954	2	7,477	**4,947**	2;103
	Unutar grupe	155,688	103	1,512		**3,09**
	Ukupno	170,642	105			
Unaprjeđenje kvalitete usluge * obrazovanje ispitanika	Između grupa	6,101	2	3,051	**1,492**	2;102
	Unutar grupe	208,527	102	2,044		**3,09**
	Ukupno	214,629	104			
Unaprjeđenje lojalnosti gostiju * obrazovanje ispitanika	Između grupa	2,841	2	1,420	**0,655**	2;101
	Unutar grupe	219,073	101	2,169		**3,09**
	Ukupno	221,913	103			
Unaprjeđenje konkurentnosti hotela * obrazovanje ispitanika	Između grupa	3,114	2	1,557	**0,757**	2;103
	Unutar grupe	211,763	103	2,056		**3,09**
	Ukupno	214,877	105			
Upravljanje podatkovnom bazom gostiju * obrazovanje ispitanika	Između grupa	1,886	2	,943	**0,519**	2;103
	Unutar grupe	187,218	103	1,818		**3,09**
	Ukupno	189,104	105			

Izvor: Izračun SPSS Statisticsa 24 temeljem podataka iz anketnog upitnika

Interpretacija: kako je vidljivo iz ANOVA tablice 86., vrijednosti F izračunato manje su od F tablično za 5% statističke značajnosti za sve funkcije osim unaprjeđenja usmjerenosti gostiju prema potrošnji što u tim slučajevima potvrđuje nul-hipotezu o ravnomjernosti distribucije ocjene neovisno o stupnju obrazovanja ispitanika. Navedena funkcija unaprjeđenja usmjerenosti gostiju prema potrošnji ukazuje na zavisnost o obrazovanju ispitanika čime se u tom segmentu prihvaća hipoteza istraživanja H_I.

Slijedi analiza varijance ocjena funkcija CRM-a prema vrsti ispitanikovih hotela.

Tablica 87. Analiza varijanci ocjena funkcija CRM-a prema vrsti hotela

Vrsta hotela		Unaprjeđenje usmjerenosti gostiju prema potrošnji	Unaprjeđenje kvalitete usluge	Unaprjeđenje lojalnosti gostiju	Unaprjeđenje konkurentnosti hotela	Upravljanje podatkovnom bazom gostiju
Kongresni	$\bar{X}$	8,6667	9,0000	9,0000	8,6667	9,0000
	% od N	2,8%	2,9%	2,9%	2,8%	2,8%
Aparthotel	$\bar{X}$	7,0000	9,0000	9,0000	8,0000	9,0000
	% od N	0,9%	1,0%	1,0%	0,9%	0,9%
Cjelogodišnji	$\bar{X}$	7,7407	7,6852	7,9615	7,7222	7,9815
	% od N	50,9%	51,4%	50,0%	50,9%	50,9%
Sezonski	$\bar{X}$	8,5208	8,5319	8,4375	8,5833	8,4583
	% od N	45,3%	44,8%	46,2%	45,3%	45,3%

ANOVA		Zbroj kvadrata	df	Srednji kvadrati	F	F granični za 5% sign.
Unaprjeđenje usmjerenosti gostiju prema potrošnji * obrazovanje ispitanika	Između grupa	17,625	3	5,875	**3,916**	2;103
	Unutar grupe	153,016	102	1,500		**3,09**
	Ukupno	170,642	105			
Unaprjeđenje kvalitete usluge * obrazovanje ispitanika	Između grupa	21,278	3	7,093	**3,705**	2;102
	Unutar grupe	193,350	101	1,914		**3,09**
	Ukupno	214,629	104			
Unaprjeđenje lojalnosti gostiju * obrazovanje ispitanika	Između grupa	8,178	3	2,726	**1,275**	2;101
	Unutar grupe	213,736	100	2,137		**3,09**
	Ukupno	221,913	103			
Unaprjeđenje konkurentnosti hotela * obrazovanje ispitanika	Između grupa	19,711	3	6,570	**3,434**	2;103
	Unutar grupe	195,167	102	1,913		**3,09**
	Ukupno	214,877	105			
Upravljanje podatkovnom bazom gostiju * obrazovanje ispitanika	Između grupa	8,206	3	2,735	**1,542**	2;103
	Unutar grupe	180,898	102	1,774		**3,09**
	Ukupno	189,104	105			

Izvor: Izračun SPSS Statisticsa 24 temeljem podataka iz anketnog upitnika

Interpretacija: kako je vidljivo iz ANOVA tablice 87., vrijednosti F izračunato manje su od F tablično za 5% statističke značajnosti za funkcije unaprjeđenje usmjerenosti gostiju prema potrošnji, unaprjeđenje kvalitete usluge i unaprjeđenje konkurentnosti hotela što u tim slučajevima potvrđuje nul-hipotezu o ravnomjernosti distribucije ocjene neovisno o vrsti hotela. Nasuprot tome kod funkcije unaprjeđenja lojalnosti gostiju i upravljanja podatkovnom bazom gostiju uočljiva je zavisnost ocjenjivanja o vrsti hotela ispitanika te se odbacuje nul-hipoteza i prihvaća hipoteza istraživanja H_I.

Shodno detektiranim različitostima koje se uočavaju pri interpretaciji rezultata pristupa se analizi korelacije srednjih vrijednosti ocjena promatranih 5 funkcija CRM-a u hotelu.

Tablica 88. Korelacija prosječnih ocjena funkcija CRM-a

		Funkcije CRM-a				
Funkcija	**Funkcije CRM-a**	1	2	3	4	5
1	Unaprjeđenje usmjerenosti gostiju prema potrošnji	1	0,719	0,528	0,602	0,558
2	Unaprjeđenje kvalitete usluge	0,719	1	0,589	0,557	0,532
3	Unaprjeđenje lojalnosti gostiju	0,528	0,589	1	0,704	0,657
4	Unaprjeđenje konkurentnosti hotela	0,602	0,557	0,704	1	0,771
5	Upravljanje podatkovnom bazom gostiju	0,558	0,532	0,657	0,771	1

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Korelacija je računata Pearsonovim koeficijentom korelacije kojim se prepoznaje povezanost ako je koeficijent veći od 0,5. Ovime je potvrđena relevantnost poznavatelja s obzirom na to da su elementi usluga internog oglašavanja kreirani na način da djeluju koordinirano.

1.31 Ocjene korisničke podrške sustava CRM-a

Korisnička podrška sustava CRM-a podrazumijeva sve aktivnosti koje se provode s gostima posredstvom informatičkih kanala komunikacije. Odnose se na sve povijesne podatke prikupljene o gostima, sve izmjene koje su nastupile i formiranje posebnih bilješki za komuniciranje s pojedinim gostom. Posredstvom korisničke podrške mogu se kontrolirati zahtjevi gostiju, primjedbe ili nezadovoljstava korištenjem različitih komunikacijskih kanala.

Ispitanicima je ponuđeno na ocjenjivanje sljedećih funkcija korisničke podrške: 1) upravljanje prodajnim procesom (rezervacija, prodaja, naplata), 2) jedinstvena lista svih gostiju, dobavljača i partnera, 3) jedinstvena lista afiniteta gostiju (grupa, parova s djecom, pojedinaca), 4) upravljanje reklamacijama, 5) praćenje konkurencije (cijene, usluge, događaji) i 6) integracija s elektroničkom poštom i potpora za *mail merge*.

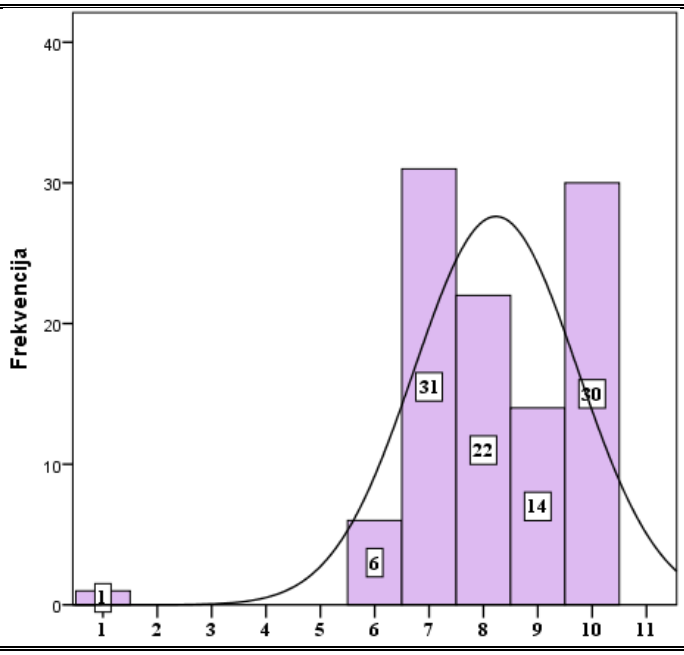
1.31.1 Upravljanje prodajnim procesom

Upravljanje prodajnim procesom je korisnička funkcija koja objedinjuje sve faze procesa prodaje hotelske usluge od upita, rezervacije, realizacije osnovne i dodatnih usluga, naplate i post-prodajnih aktivnosti. Ova funkcija također korisniku omogućuje da se komunikacija s gostom ne ponavlja nepotrebno što može iritirati gosta.

Od ukupno 106 ispitanika njih 104 (98,1%) ocijenilo je korisničku funkciju CRM-a upravljanje prodajnim procesom. Dvoje ispitanika (1,9%) nije dalo svoje ocjene na postavljeno pitanje. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 89. Frekvencija i distribucija ocjena funkcije CRM-a upravljanja prodajnim procesom

Upravljanje podatkovnom bazom gostiju		F	%	Histogram ocjena funkcije 6.
	1	1	1	
	6	6	5,8	
	7	31	29,8	
	8	22	21,2	
	9	14	13,5	
	10	30	28,8	
	Ukupno	104	100	
$\bar{X}$		8,2308		
Medijan		8,00		
Mod		7,00		
SD		1,5023		
Varijanca σ²		2,257		
Raspon		9		
Σ		856		
Skewness		-0,964		
Kurtosis		3,481		
Percentil	25	7		
	50	8		
	75	10		



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 89. vidljivo je kako su ispitanici ocjenjivali ovu funkciju u rasponu ocjena od 1 do 10. Jedan je ispitanik (1%) dodijelio ocjenu 1 dok je 30 ispitanika (28,8%) dodijelilo maksimalnu ocjenu 10. Ocjena 7 je istaknuta (29,8%). Priloženi histogram jasno predočava kako ocjene funkcije CRM-a upravljanje prodajom ne prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je umjerena i negativna -0,964 što ukazuje na umjeren pomak prema većim ocjenama.

Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 3,481 što označava srednje jaku leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Ispitanici su promatranu funkciju CRM-a ocijenili prosječnom ocjenom 8,2308 uz standardnu devijaciju od 1,5023 i varijancu 2,257.

Ocjene korisničke funkcije upravljanja prodajnim procesom prema profilu ispitanika i objekta predočavaju se narednom tablicom.

Tablica 90. Ocjene korisničke funkcije upravljanja prodajnim procesom prema profilu ispitanika i objekta

Profil ispitanika	$\bar{X}$	Profil objekta	$\bar{X}$
POZICIJA		**LOKACIJA HOTELA**	
Direktor hotela	8,13	Kontinent	8,41
Direktor marketinga	8,61	Otoci	7,25
Šef recepcije	8,02	Priobalje	8,66
		Urbani	7,94
STAROSNA DOB		**VELIČINA HOTELA**	
Do 35 godina	8,38	Od 101 do 200 soba	8,66
Od 36 do 45 godina	8,51	Manje od 100 soba	8,21
Od 46 do 55 godina	8,06	Više od 200 soba	7,5
Više od 56 godina	7,75		
OBRAZOVANJE		**VRSTA HOTELA**	
Mr, Dr	7,62	Aparthotel	8,00
VSS	8,48	Cjelogodišnji	8,04
VŠS	8,16	Kongresni, sportski	9,00
		Sezonski	8,41
RADNI STAŽ		**NAMJENA HOTELA**	
Od 11 do 20 godina	8,29	Kongresi	9,62
Od 21 do 30 godina	8,34	Odmor	8,047
Više od 30 godina	7,6	Sport i zabava	8,73
Do 5 godina	7,0	Urbani	7,89
Od 6 do 10 godina	8,27	Zdravlje i *wellness*	8,23

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Tablicom 90. predočava se sistematizirani prikaz prosječnih ocjena funkcije upravljanje prodajnim procesom koje su dodjeljivali ispitanici s obzirom na svoje osobne karakteristike i karakteristike hotela u kojem rade. Pojednostavljeni zaključak koji se iščitava je da korisničku funkciju upravljanja prodajnim procesima najviše uvažavaju visokoobrazovani direktori marketinga starosne dobi između 36 i 45 godina te s radnim iskustvom između 21 i 30 godina koji radi u hotelu srednje veličine na priobalju koji je namijenjen kongresnim i sportskom događanjima.

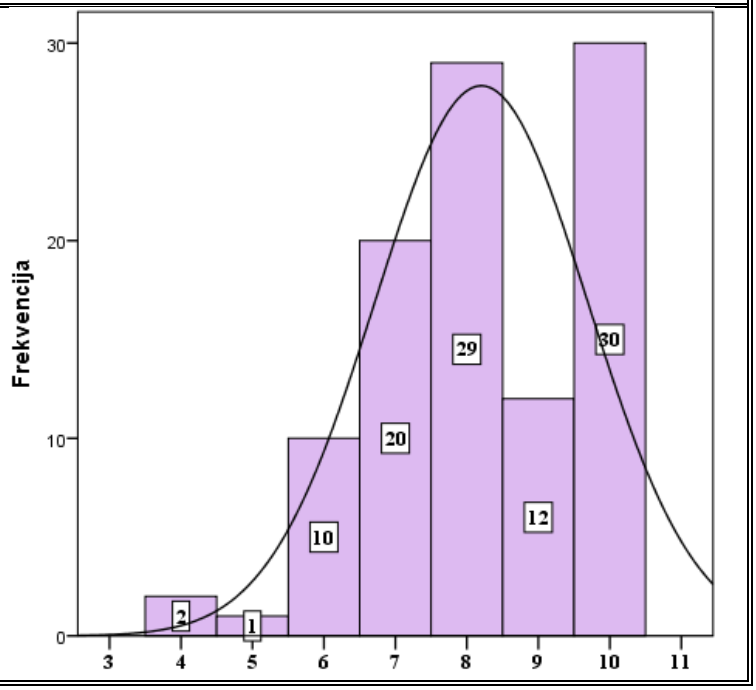
1.31.2 Jedinstvena lista svih gostiju, dobavljača i partnera

Korisnička funkcija CRM-a koja omogućuje jedinstvenu listu svih gostiju, dobavljača i partnera važna je sama po sebi čak i da se ne koristi kao softverski alat s obzirom na to da su spoznaje o dobavljačima i partnerima u dinamičnim uvjetima na tržištu važne za planiranje kapaciteta popunjenosti i odnosa s kupcima.

Od ukupno 106 ispitanika njih 104 (98,1%) ocijenilo je korisničku funkciju CRM-a jedinstvena lista gostiju, dobavljača i partnera. Dvoje ispitanika (1,9%) nije dalo svoje ocjene na postavljeno pitanje. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 91. Frekvencija i distribucija ocjena funkcije CRM-a jedinstvena lista gostiju, dobavljača i partnera

Jedinstvena lista gostiju, dobavljača i partnera		**F**	**%**	**Histogram ocjena funkcije 7.**
	4	2	1,9	
	5	1	1	
	6	10	9,6	
	7	20	19,2	
	8	29	27,9	
	9	12	11,5	
	10	30	28,8	
	Ukupno	104	100	
$\bar{X}$		8,2019		
Medijan		8,00		
Mod		10		
SD		1,49029		
Varijanca σ^2		2,221		
Raspon		6		
Σ		853		
Skewness		-0,426		
Kurtosis		-0,327		
Percentil	25	7		
	50	8		
	75	10		



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 91. vidljivo je kako su ispitanici ocjenjivali ovu funkciju u rasponu ocjena od 4 do 10. Dva su ispitanika (1,9%) dodijelila ocjenu 4 dok je 30 ispitanika (28,8%) dodijelilo maksimalnu ocjenu 10. Ocjena 8 je druga istaknuta (27,9%). Priloženi histogram jasno predočava kako ocjene funkcije CRM-a jedinstvena lista kupaca, dobavljača i partnera ne prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,426 što ukazuje na umjeren pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost -0,327 što označava slabu platikurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Ispitanici su promatranu funkciju CRM-a ocijenili prosječnom ocjenom 8,2019 uz standardnu devijaciju od 1,49029 i varijancu 2,221. Narednom se tablicom predočava kako su ispitanici ocjenjivali ovu korisničku funkciji prema profilu ispitanika i objekta.

Ocjene korisničke funkcije jedinstvene liste gostiju, dobavljača i partnera prema profilu ispitanika i objekta predočavaju se narednom tablicom

Tablica 92. Ocjene korisničke funkcije jedinstvene liste gostiju, dobavljača i partnera prema profilu ispitanika i objekta

Profil ispitanika	$\bar{X}$	**Profil objekta**	$\bar{X}$
POZICIJA		**LOKACIJA HOTELA**	
Direktor hotela	7,70	Kontinent	8,47
Direktor marketinga	8,68	Otoci	7,13
Šef recepcije	8,21	Priobalje	8,46
		Urbani	8,16
STAROSNA DOB		**VELIČINA HOTELA**	
Do 35 godina	8,13	Od 101 do 200 soba	8,65
Od 36 do 45 godina	8,6	Manje od 100 soba	8,17
Od 46 do 55 godina	7,88	Više od 200 soba	7,45
Više od 56 godina	7,94		
OBRAZOVANJE		**VRSTA HOTELA**	
Mr., dr.	7,38	Aparthotel	7,00
VSS	8,32	Cjelogodišnji	8,08
VŠS	8,39	Kongresni, sportski	9,33
		Sezonski	8,30
RADNI STAŽ		**NAMJENA HOTELA**	
Od 11 do 20 godina	8,14	Kongresi	9,75
Od 21 do 30 godina	8,49	Odmor	7,96
Više od 30 godina	7,80	Sport i zabava	8,64
Do 5 godina	6,33	Urbani	7,89
Od 6 do 10 godina	8,19	Zdravlje i *wellness*	9,00

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Tablicom 92. predočen je sistematizirani prikaz prosječnih ocjena funkcije jedinstvene liste svih gostiju, dobavljača i partnera koje su dodjeljivali ispitanici s obzirom na svoje osobne karakteristike i karakteristike hotela u kojem rade. Pojednostavljeni zaključak koji se iščitava jest da korisničku funkciju jedinstvene liste svih gostiju, dobavljača i partnera najviše uvažavaju visokoobrazovani direktori marketinga starosne dobi između 36 i 45 godina i s radnim iskustvom između 21 i 30 godina koji rade u hotelu srednje veličine na priobalju koji je namijenjen kongresima te zdravlju i *wellnessu*.

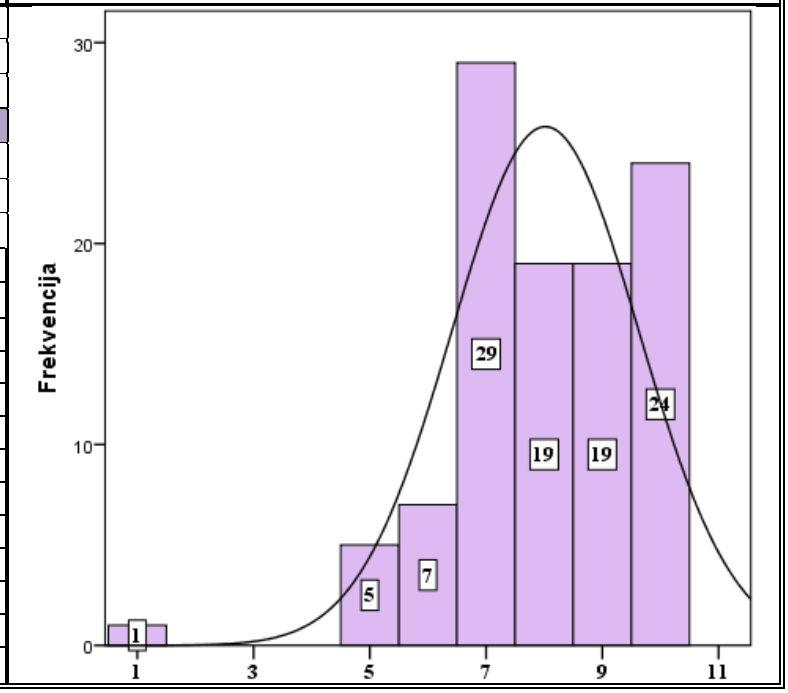
1.31.3 Jedinstvena lista afiniteta gostiju

Jedinstvena lista afiniteta gostiju (grupa, parova s djecom, pojedinaca) koju CRM formira temeljem povijesnih podataka iz baze gostiju i elektroničke korespondencije snažan su marketinški alat za ostvarivanje lojalnosti kostiju.

Od ukupno 106 ispitanika njih 104 (98,1%) ocijenilo je korisničku funkciju CRM-a jedinstvenu listu afiniteta gostiju. Dvoje ispitanika (1,9%) nije dalo svoje ocjene na postavljeno pitanje. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 93. Frekvencija i distribucija ocjena funkcije CRM-a jedinstvena lista afiniteta gostiju

Jedinstvena lista afiniteta gostiju		**F**	**%**
	1	1	1
	5	5	4,8
	6	7	6,7
	7	29	27,9
	8	19	18,3
	9	19	18,3
	10	24	23,1
	Ukupno	104	100
$\bar{X}$		8,0192	
Medijan		8,00	
Mod		7,00	
SD		1,60691	
Varijanca σ^2		2,258	
Raspon		9	
Σ		834	
Skewness		-0,876	
Kurtosis		2,124	
Percentil	25	7	
	50	8	
	75	9	



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 93. vidljivo je kako su ispitanici ocjenjivali ovu funkciju u rasponu ocjena od 4 do 10. Jedan je ispitanik (1,0%) dodijelio ocjenu 1 dok su 24 ispitanika (23,1%) dodijelili maksimalnu ocjenu 10. Ocjena 7 je istaknuta (27,9%). Priloženi histogram jasno predočava kako ocjene funkcije CRM-a jedinstvena lista afiniteta gostiju ne prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je umjerena i negativna -0,876 što ukazuje na umjeren pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 2,124 što označava umjerenu leptokurtičnost koja se ogleda u grupiranju rezultata

oko aritmetičke sredine. Ispitanici su promatranu funkciju CRM-a ocijenili prosječnom ocjenom 8,0192 uz standardnu devijaciju od 1,60691 i varijancu 2,258. Narednom tablicom predočava se kako su ispitanici ocjenjivali ovu korisničku funkciji prema profilu ispitanika i objekta.

Ocjene korisničke funkcije jedinstvene liste afiniteta gostiju prema profilu ispitanika i objekta predočavaju se narednom tablicom.

Tablica 94. Ocjene korisničke funkcije jedinstvene liste afiniteta gostiju prema profilu ispitanika i objekta

Profil ispitanika	$\bar{X}$	**Profil objekta**	$\bar{X}$
POZICIJA		**LOKACIJA HOTELA**	
Direktor hotela	7,67	Kontinent	8,56
Direktor marketinga	8,35	Otoci	7,44
Šef recepcije	8,02	Priobalje	8,03
		Urbani	7,53
STAROSNA DOB		**VELIČINA HOTELA**	
Do 35 godina	7,88	Od 101 do 200 soba	8,63
Od 36 do 45 godina	8,67	Manje od 100 soba	7,79
Od 46 do 55 godina	7,67	Više od 200 soba	7,36
Više od 56 godina	7,31		
OBRAZOVANJE		**VRSTA HOTELA**	
Mr., dr.	7,38	Aparthotel	9,00
VSS	8,20	Cjelogodišnji	7,72
VŠS	8,05	Kongresni, sportski	8,67
		Sezonski	8,30
RADNI STAŽ		**NAMJENA HOTELA**	
Od 11 do 20 godina	8,03	Kongresi	9,25
Od 21 do 30 godina	8,14	Odmor	7,82
Više od 30 godina	7,40	Sport i zabava	8,73
Do 5 godina	6,00	Urbani	7,22
Od 6 do 10 godina	8,19	Zdravlje i *wellness*	9,00

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Tablicom 94. predočen je sistematizirani prikaz prosječnih ocjena funkcije jedinstvene liste afiniteta gostiju koje su dodjeljivali ispitanici s obzirom na svoje osobne karakteristike i karakteristike hotela u kojem rade. Pojednostavljeni zaključak koji se iščitava je da korisničku funkciju jedinstvene liste svih gostiju, dobavljača i partnera najviše uvažavaju visokoobrazovani direktori marketinga starosne dobi između 36 i 45 godina te s radnim iskustvom između 21 i 30 godina koji radi u aparthotelu srednje veličine na kontinentu koji je namijenjen kongresima.

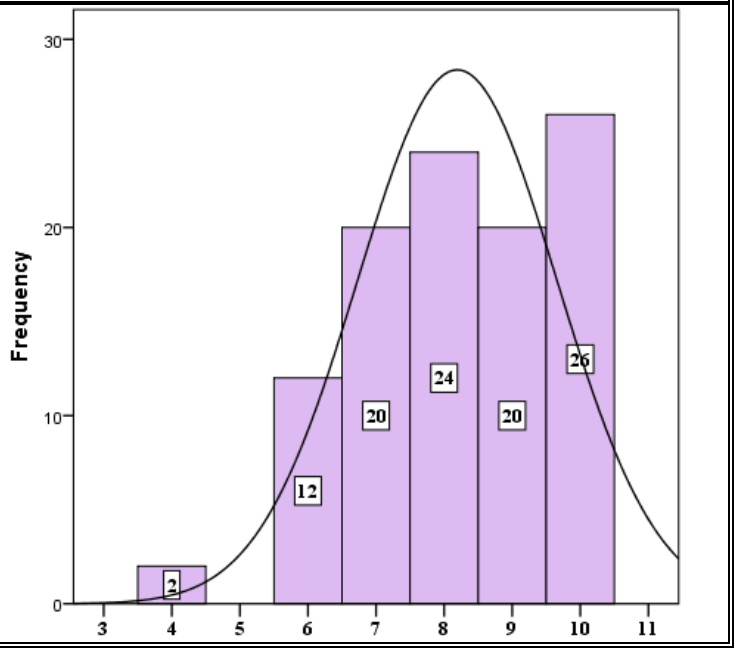
1.31.4 Upravljanje reklamacijama

Upravljanje reklamacijama korisnička je podrška koja omogućuje jednostavno detektiranje opravdanosti uložene reklamacije. Unatoč pravilu kako je gost uvijek u pravu, ova funkcija omogućuje analizu učestalosti pritužbi, komparaciju sa sličnim pritužbama, ponavljanje sudionika spora (konobar, sobar, kuhar) i načina izbjegavanja konfliktnih situacija.

Od ukupno 106 ispitanika njih 104 (98,1%) ocijenilo je korisničku funkciju CRM-a upravljanje reklamacijama. Dvoje ispitanika (1,9%) nije dalo svoje ocjene na postavljeno pitanje. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 95. Frekvencija i distribucija ocjena funkcije CRM-a upravljanje reklamacijama

Upravljanje reklamacijama		**F**	**%**	**Histogram ocjena funkcije 9.**
	4	2	1,9	
	6	12	11,5	
	7	20	19,2	
	8	24	23,1	
	9	20	19,2	
	10	26	25	
	Ukupno	104	100	
$\bar{X}$		8,1923		
Medijan		8,00		
Mod		10		
SD		1,46199		
Varijanca σ^2		2,137		
Raspon		6		
Σ		852		
Skewness		-0,455		
Kurtosis		-0,338		
Percentil	25	7		
	50	8		
	75	9,75		



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 95. vidljivo je kako su ispitanici ocjenjivali ovu funkciju u rasponu ocjena od 4 do 10. Dva su ispitanika (1,9%) dodijelila ocjenu 4 dok je 26 ispitanika (25,0%) dodijelilo maksimalnu ocjenu 10. Ocjena 8 je druga istaknuta (27,9%). Priloženi histogram jasno predočava kako ocjene funkcije CRM-a upravljanje reklamacijama ne prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je slaba i negativna -0,426 što ukazuje na umjeren pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima

vrijednost -0,327 što označava slabu platikurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Ispitanici su promatranu funkciju CRM-a ocijenili prosječnom ocjenom 8,1923 uz standardnu devijaciju od 1,496199 i varijancu 2,137.

Narednom tablicom predočava se kako su ispitanici ocjenjivali ovu korisničku funkciji prema profilu ispitanika i objekta.

Tablica 96. Ocjene korisničke funkcije upravljanja reklamacijama prema profilu ispitanika i objekta

Profil ispitanika	$\bar{X}$	**Profil objekta**	$\bar{X}$
POZICIJA		**LOKACIJA HOTELA**	
Direktor hotela	8,13	Kontinent	8,61
Direktor marketinga	8,62	Otoci	7,13
Šef recepcije	8,09	Priobalje	8,63
		Urbani	7,44
STAROSNA DOB		**VELIČINA HOTELA**	
Do 35 godina	8,13	Od 101 do 200 soba	8,58
Od 36 do 45 godina	8,62	Manje od 100 soba	8,02
Od 46 do 55 godina	8,09	Više od 200 soba	7,82
Više od 56 godina	7,44		
OBRAZOVANJE		**VRSTA HOTELA**	
Mr., dr.	7,88	Aparthotel	8,00
VSS	8,22	Cjelogodišnji	8,02
VŠS	8,29	Kongresni, sportski	8,33
		Sezonski	8,41
RADNI STAŽ		**NAMJENA HOTELA**	
Od 11 do 20 godina	8,40	Kongresi	9,38
Od 21 do 30 godina	8,17	Odmor	8,06
Više od 30 godina	7,80	Sport i zabava	8,82
Do 5 godina	6,67	Urbani	7,33
Od 6 do 10 godina	8,19	Zdravlje i *wellness*	8,5

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Tablicom 96. predočen je sistematizirani prikaz prosječnih ocjena funkcije upravljanja reklamacijama koje su dodjeljivali ispitanici s obzirom na svoje osobne karakteristike i karakteristike hotela u kojem rade. Pojednostavljeni zaključak koji se iščitava je da korisničku funkciju upravljanje reklamacijama najviše uvažavaju visokoobrazovani direktori marketinga starosne dobi između 36 i 45 godina i s radnim iskustvom između 11 i 20 godina koji radi u sezonskom hotelu srednje veličine na priobalju koji je namijenjen kongresima.

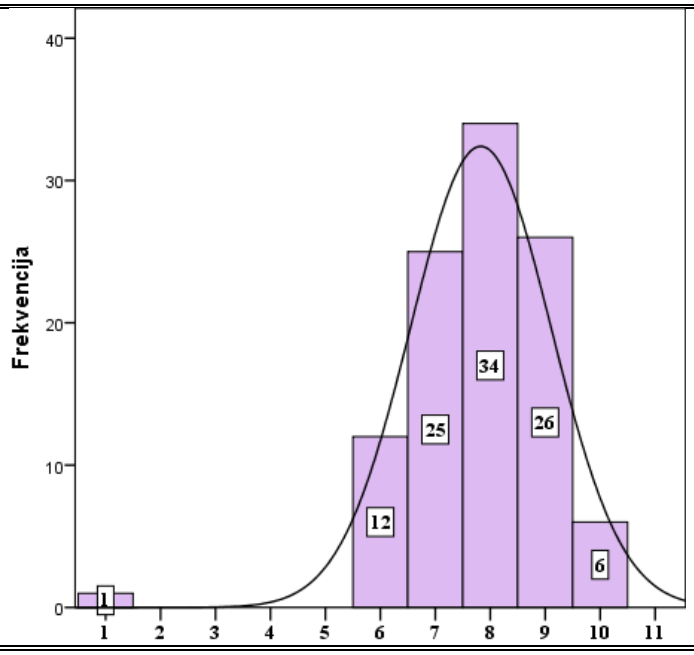
1.31.5 Praćenje konkurencije

Praćenje konkurencije (cijene, usluge, događaji) je uobičajen menadžerski posao kojim nastoji zaštititi svoje poslovanje. CRM mu to omogućuje za sve javno objavljene podatke. Ono ne uključuje industrijsku špijunažu s obzirom na to da gotovo sva hotelska poduzeća nastoje što širem krugu potencijalnih korisnika javno obznaniti svoje cijene, pogodnosti događanja i sl. Pored toga postoje i brojni specijalizirani agenti i portali koji kompariraju hotelske usluge.

Od ukupno 106 ispitanika njih 104 (98,1%) ocijenilo je korisničku funkciju CRM-a praćenje konkurencije. Dvoje ispitanika (1,9%) nije dalo svoje ocjene na postavljeno pitanje. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 97. Frekvencija i distribucija ocjena funkcije CRM-a praćenje konkurencije

Praćenje konkurencije		**F**	**%**	**Histogram ocjena funkcije 10.**
	1	1	1	
	6	12	11,5	
	7	25	24	
	8	34	32,7	
	9	26	25	
	10	6	5,8	
	Ukupno	104	100	
$\bar{X}$		7,8269		
Medijan		8,00		
Mod		8		
SD		1,28049		
Varijanca σ^2		1,640		
Raspon		9		
Σ		814		
Skewness		-1,423		
Kurtosis		6,483		
Percentil	25	7		
	50	8		
	75	9		



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 97. vidljivo je kako su ispitanici ocjenjivali ovu funkciju u rasponu ocjena od 1 do 10. Jedan je ispitanik (1,0%) dodijelio ocjenu 1 dok je 6 ispitanika (5,8%) dodijelilo maksimalnu ocjenu 10. Ocjena 8 je istaknuta (32,7%). Priloženi histogram jasno predočava kako ocjene funkcije CRM-a praćenje konkurencije ne prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je umjerena i negativna -1,423 što ukazuje na umjeren

pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 6,483 što označava znatnu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Ispitanici su promatranu funkciju CRM-a ocijenili prosječnom ocjenom 7,8269 uz standardnu devijaciju od 1,28049 i varijancu 1,640. Narednom tablicom predočava se kako su ispitanici ocjenjivali ovu korisničku funkciji prema profilu ispitanika i objekta.

Tablica 98. Ocjene korisničke funkcije praćenja konkurencije prema profilu ispitanika i objekta

Profil ispitanika	$\bar{X}$	**Profil objekta**	$\bar{X}$
POZICIJA		**LOKACIJA HOTELA**	
Direktor hotela	7,93	Kontinent	8,03
Direktor marketinga	7,81	Otoci	7,13
Šef recepcije	7,77	Priobalje	8,06
		Urbani	7,63
STAROSNA DOB		**VELIČINA HOTELA**	
Do 35 godina	7,62	Od 101 do 200 soba	8,23
Od 36 do 45 godina	8,10	Manje od 100 soba	7,71
Od 46 do 55 godina	7,67	Više od 200 soba	7,32
Više od 56 godina	7,69		
OBRAZOVANJE		**VRSTA HOTELA**	
Mr., dr.	7,63	Aparthotel	9,00
VSS	7,98	Cjelogodišnji	7,67
VŠS	7,83	Kongresni, sportski	8,00
		Sezonski	7,98
RADNI STAŽ		**NAMJENA HOTELA**	
Od 11 do 20 godina	8,00	Kongresi	8,38
Od 21 do 30 godina	7,77	Odmor	7,79
Više od 30 godina	7,40	Sport i zabava	8,00
Do 5 godina	5,33	Urbani	7,44
Od 6 do 10 godina	8,04	Zdravlje i *wellness*	7,75

Izvor: obrada autora u IBM SPSS Statisticu prema podatcima anketnog upitnika

Tablicom 98. predočen je sistematizirani prikaz prosječnih ocjena funkcije praćenje konkurencije koje su dodjeljivali ispitanici s obzirom na svoje osobne karakteristike i karakteristike hotela u kojem rade.

Pojednostavljeni zaključak koji se iščitava je da korisničku funkciju praćenja konkurencije najviše uvažavaju visokoobrazovani direktori hotela srednje starosne dobi do 10 godina radnog staža u srednjim aparthotelima u priobalju namijenjenih kongresnom turizmu srednje veličine na priobalju koji je namijenjen kongresima.

1.31.6 Integracija s elektroničkom poštom i potpora za mail merge

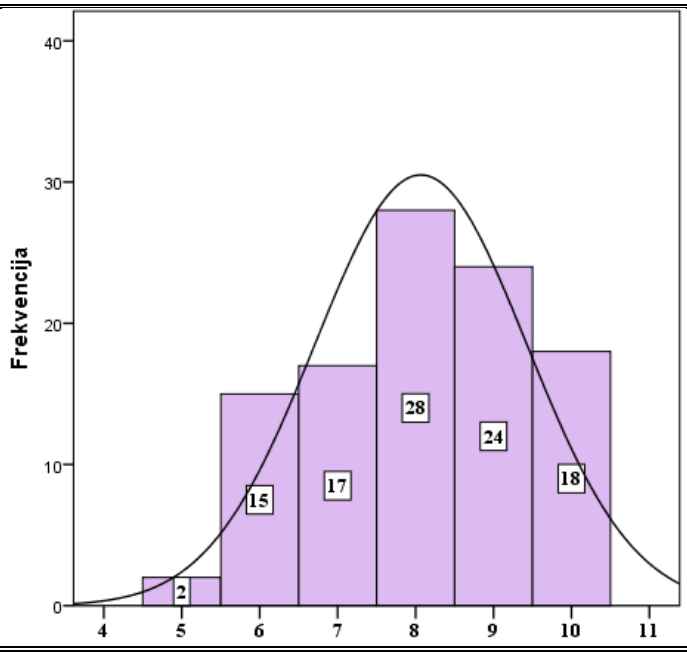
Integracija s elektroničkom poštom i potpora za *mail merge* korisnička je podrška koju pruža CRM s ciljem odašiljanja ciljanih masovnih individualiziranih poruka. To se primjerice odnosi na čestitanje vjerskih i nacionalnih blagdana, rođendana ili podsjećanja na zajednička druženja. CRM podržava e-adrese i brojeve mobitela te se poruke odašilju na više komunikacijskih kanala. CRM „ne zaboravlja" ni one goste koji preferiraju klasične poštanske čestitke.

Od ukupno 106 ispitanika njih 104 (98,1%) ocijenilo je korisničku funkciju CRM-a integracija s elektroničkom poštom i potpora za mail merge. Dvoje ispitanika (1,9%) nije dalo svoje ocjene na postavljeno pitanje. Frekvencija i distribucija ocjena predočava se narednom složenom tablicom.

Tablica 99. Frekvencija i distribucija ocjena funkcije CRM-a integracija s elektroničkom poštom i potpora za mail merge

Integracija s elektroničkom poštom i potpora za mail merge		**F**	**%**
	5	2	1,9
	6	15	14,4
	7	17	16,3
	8	28	26,9
	9	24	23,1
	10	18	17,3
	Ukupno	104	100
$\bar{X}$		8,0673	
Medijan		8,00	
Mod		8,0	
SD		1,36007	
Varijanca σ^2		1,850	
Raspon		5	
Σ		839	
Skewness		-0,857	
Kurtosis		0,469	
Percentil	25	7	
	50	8	
	75	9	

Histogram ocjena funkcije 11.



Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz tablice 99. vidljivo je kako su ispitanici ocjenjivali ovu funkciju u rasponu ocjena od 5 do 10. Dva su ispitanika (1,9%) dodijelila ocjenu 5 dok je 18 ispitanika (17,3%) dodijelilo maksimalnu ocjenu 10. Ocjena 8 je istaknuta (26,9%). Priloženi histogram jasno predočava kako ocjene funkcije CRM-a integracija s elektroničkom poštom i potpora za mail merge prate normalnu razdiobu. Mjera asimetrije normalne krivulje Skewness je umjerena i

negativna -0,857 što ukazuje na umjeren pomak prema većim ocjenama. Mjera spljoštenosti krivulje je Kurtosis koja ima vrijednost 0,469 što označava slabu leptokurtičnost koja se ogleda u grupiranju rezultata oko aritmetičke sredine. Ispitanici su promatranu funkciju CRM-a ocijenili prosječnom ocjenom 8,0673 uz standardnu devijaciju od 1,36007 i varijancu 1,850. Narednom tablicom predočava se kako su ispitanici ocjenjivali ovu korisničku funkciji prema profilu ispitanika i objekta.

Tablica 100. Ocjene korisničke funkcije integracija s elektroničkom poštom i potpora za mail merge

Profil ispitanika	$\bar{X}$	**Profil objekta**	$\bar{X}$
POZICIJA		**LOKACIJA HOTELA**	
Direktor hotela	7,83	Kontinent	8,29
Direktor marketinga	8,48	Otoci	7,00
Šef recepcije	7,93	Priobalje	8,54
		Urbani	7,68
STAROSNA DOB		**VELIČINA HOTELA**	
Do 35 godina	7,88	Od 101 do 200 soba	8,50
Od 36 do 45 godina	8,44	Manje od 100 soba	8,05
Od 46 do 55 godina	7,88	Više od 200 soba	7,32
Više od 56 godina	7,75		
OBRAZOVANJE		**VRSTA HOTELA**	
Mr., dr.	7,56	Aparthotel	7,00
VSS	8,28	Cjelogodišnji	7,93
VŠS	8,00	Kongresni, sportski	8,33
		Sezonski	8,24
RADNI STAŽ		**NAMJENA HOTELA**	
Od 11 do 20 godina	8,29	Kongresi	9,00
Od 21 do 30 godina	8,11	Odmor	7,90
Više od 30 godina	7,40	Sport i zabava	8,55
Do 5 godina	7,33	Urbani	789
Od 6 do 10 godina		Zdravlje i *wellness*	8,25

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Tablicom 100. predočen je sistematizirani prikaz prosječnih ocjena funkcije integracija s elektroničkom poštom i potpora za *mail merge* koje su dodjeljivali ispitanici s obzirom na svoje osobne karakteristike i karakteristike hotela u kojem rade. Pojednostavljeni zaključak koji se iščitava jest da korisničku funkciju praćenja konkurencije najviše uvažavaju visokoobrazovani direktori marketinga starosne dobi između 36 i 45 godina do 20 godina radnog staža u hotelima srednje veličine na priobalju koji je namijenjen kongresima.

1.31.7 Analiza korisničke podrške CRM-a

Analogno dosad analiziranim elementima integriranih informacijsko-komunikacijskih usluga u hotelu analiziraju se i korisničke funkcije sustava CRM-a. Kao metode kojom se istražuju

povezanosti između pojedinih varijabli (funkcija) koristi se analiza varijance ANOVA. Istražiti će se povezanost prema poziciji ispitanika u hotelu i lokaciji hotela.

Postavlja se hipoteza istraživanja H_I kako pozicija ispitanika u hotelu utječe na distribuciju ocjena korisničkih funkcija CRM-a. Kako su ispitanici dodjeljivali svoje ocjene pojedinim funkcijama i kakva je njihova međusobna povezanost u odnosu na ispitanikovu poziciju predočava se narednom tablicom.

Tablica 101. Analiza varijanci ocjena korisničkih funkcija CRM-a prema poziciji ispitanika

Pozicija ispitanika		Upravljanje prodajnim procesom	Jedinstvena lista gostiju, dobavljača i partnera	Jedinstvena lista afiniteta gostiju	Upravljanje reklamacijama	Praćenje konkurencije	Integracija s e-poštom
Direktor hotela	$\bar{X}$	8,1333	7,7000	7,6667	8,0000	7,9333	7,8333
	% od N	28,8%	28,8%	28,8%	28,8%	28,8%	28,8%
Direktor market.	$\bar{X}$	8,6129	8,6774	8,3548	8,2903	7,8065	8,4839
	% od N	29,8%	29,8%	29,8%	29,8%	29,8%	29,8%
Šef recepcije	$\bar{X}$	8,0233	8,2093	8,0233	8,2558	7,7674	7,9302
	% od N	41,3%	41,3%	41,3%	41,3%	41,3%	41,3%

ANOVA		Zbroj kvadrata	df	Srednji kvadrati	F	F granični za 5% sign.
Upravljanje prodajnim procesom * pozicija ispitanika	Između grupa	6,663	2	3,332	**1,490**	2;101
	Unutar grupe	225,798	101	2,236		**3,09**
	Ukupno	232,462	103			
Jedinstvena lista gostiju, dobavljača i partnera * pozicija ispitanika	Između grupa	14,569	2	7,285	**3,435**	2;101
	Unutar grupe	214,190	101	2,121		**3,09**
	Ukupno	228,760	103			
Jedinstvena lista afiniteta gostiju * pozicija ispitanika	Između grupa	7,221	2	3,611	**1,409**	2;101
	Unutar grupe	258,740	101	2,562		**3,09**
	Ukupno	265,962	103			
Upravljanje reklamacijama * pozicija ispitanika	Između grupa	1,581	2	,790	**0,365**	2;101
	Unutar grupe	218,573	101	2,164		**3,09**
	Ukupno	220,154	103			
Praćenje konkurencije * pozicija ispitanika	Između grupa	,505	2	,252	**0,151**	2;101
	Unutar grupe	168,380	101	1,667		**3,09**
	Ukupno	168,885	103			
Integracija s e-poštom * pozicija ispitanika	Između grupa	7,830	2	3,915	**2,164**	2;101
	Unutar grupe	182,699	101	1,809		**3,09**
	Ukupno	190,529	103			

Izvor: Izračun SPSS Statisticsa 24 temeljem podataka iz anketnog upitnika

Interpretacija: kako je vidljivo iz ANOVA tablice 101., vrijednosti F izračunato su manje od F tablično za 5% statističke značajnosti za sve funkcije osim jedinstvene liste gostiju, dobavljača i partnera što u tim slučajevima potvrđuje nul-hipotezu o ravnomjernosti distribucije ocjene neovisno o stupnju obrazovanja ispitanika. Navedena korisnička funkcija jedinstvene liste gostiju, dobavljača i partnera ukazuje na zavisnost o poziciji ispitanika čime se u tom segmentu prihvaća hipoteza istraživanja H_I.

Slijedi analiza varijance ocjena korisničkih funkcija CRM-a prema lokaciji ispitanikovih hotela

Tablica 102. Analiza varijanci ocjena korisničkih funkcija CRM-a prema lokaciji hotela

Lokacija hotela		Upravljanje prodajnim procesom	Jedinstvena lista gostiju, dobavljača i partnera	Jedinstvena lista afiniteta gostiju	Upravljanje reklamacijama	Praćenje konkurencije
Kontinent	$\bar{X}$	8,4118	8,4706	8,5588	8,6176	8,0294
	% od N	32,7%	32,7%	32,7%	32,7%	32,7%
Otoci	$\bar{X}$	7,2500	7,1250	7,4375	7,1250	7,1250
	% od N	15,4%	15,4%	15,4%	15,4%	15,4%
Priobalje	$\bar{X}$	8,6571	8,4571	8,0286	8,6286	8,0571
	% od N	33,7%	33,7%	33,7%	33,7%	33,7%
Urbani	$\bar{X}$	7,9474	8,1579	7,5263	7,5263	7,6316
	% od N	18,3%	18,3%	18,3%	18,3%	18,3%

ANOVA		Zbroj kvadrata	df	Srednji kvadrati	F	F granični za 5% sign.
Upravljanje prodajnim procesom * lokacija hotela	Između grupa	24,393	3	8,131	**3,908**	2;100
	Unutar grupe	208,068	100	2,081		**2,70**
	Ukupno	232,462	103			
Jedinstvena lista gostiju, dobavljača i partnera * lokacija hotela	Između grupa	23,327	3	7,776	**3,785**	2;100
	Unutar grupe	205,433	100	2,054		**2,70**
	Ukupno	228,760	103			
Jedinstvena lista afiniteta gostiju * lokacija hotela	Između grupa	19,933	3	6,644	**2,701**	3;100
	Unutar grupe	246,028	100	2,460		**2,70**
	Ukupno	265,962	103			
Upravljanje reklamacijama * lokacija hotela	Između grupa	39,466	3	13,155	**7,281**	2;100
	Unutar grupe	180,688	100	1,807		**2,70**
	Ukupno	220,154	103			
Praćenje konkurencije * lokacija hotela	Između grupa	11,857	3	3,952	**2,517**	3;100
	Unutar grupe	157,027	100	1,570		**2,70**
	Ukupno	168,885	103			
Integracija s e-poštom * lokacija hotela	Između grupa	30,679	3	10,226	**6,397**	3;100
	Unutar grupe	159,850	100	1,598		2,70
	Ukupno	190,529	103			

Izvor: Izračun SPSS Statisticsa 24 temeljem podataka iz anketnog upitnika

Interpretacija: kako je vidljivo iz ANOVA tablice 102., vrijednost F izračunato je manja od F tablično za 5% statističke značajnosti za korisničku funkciju praćenje konkurencije što u tom slučaju potvrđuje nul-hipotezu o ravnomjernosti distribucije ocjene neovisno o lokaciji hotela. Nasuprot tome kod svih ostalih korisničkih funkcija uočljiva je zavisnost ocjenjivanja o lokalitetu hotela ispitanika te se odbacuje nul-hipoteza i prihvaća hipoteza istraživanja H_I.

Shodno detektiranim različitostima koje se uočavaju pri interpretaciji rezultata pristupa se analizi korelacije srednjih vrijednosti ocjena promatranih 6 korisničkih funkcija CRM-a u hotelu.

Tablica 103. Korelacija funkcija korisničke podrške

		FUNKCIJE KORISNIČKE PODRŠKE					
Funkcija	**KORISNIČKE PODRŠKE CRM-a**	1	2	3	4	5	6
1	Upravljanje prodajnim procesom	1,00	0,68	0,79	0,67	0,58	0,72
2	Jedinstvena lista gostiju, dobavljača i partnera	0,68	1,00	0,75	0,70	0,60	0,63
3	Jedinstvena lista afiniteta gostiju	0,79	0,75	1,00	0,75	0,49	0,57
4	Upravljanje reklamacijama	0,67	0,70	0,75	1,00	0,66	0,70
5	Praćenje konkurencije	0,58	0,60	0,49	0,66	1,00	0,63
6	Integracija elektronske pošte	0,72	0,63	0,57	0,70	0,63	1,00

Izvor: obrada autora u IBM SPSS Statisticsu 24 prema podatcima anketnog upitnika

Korelacija je računata Pearsonovim koeficijentom korelacije kojim se prepoznaje povezanost ako je koeficijent veći od 0,5. Time je potvrđena relevantnost poznavatelja s obzirom na to da su funkcije CRM-a kreirane na način da djeluju koordinirano.

1.32 Razvojni elementi CRM-a

Anketnim upitnikom ekspertima iz područja hotelijerstva ponuđeno je da ocijene (u rasponu od 1-10) aktualnu vrijednost pojedinog elementa razvoja CRM-a te poznavanjem općeg stanja u hotelijerskoj industriji, trendova na turističkom tržištu te kretanja u društvu i gospodarstvu projiciraju buduću vrijednost tih elemenata za narednih 5 godina.

1. ***Ljudski potencijali – spremnost prihvaćanja i korištenja CRM-a.*** Stručnost i spremnost ljudskih potencijala u hotelskoj industriji da prihvate i koriste CRM je od ispitanika za 2019. godinu ocijenjena prosječnom ocjenom 7,58 uz SD 0,9515 i varijancu σ^2 od 0,905, te za

2024. godinu prosječnom ocjenom 9,53 uz SD 0,667 i varijancu σ^2 od 0,446. Time je projicirano poboljšanje za 25,6%

2. ***ICT infrastruktura*** je ključan preduvjet razvoja upravljanja odnosima s gostima koji je za 2019. godinu ocijenjen prosječnom ocjenom 7,61 uz SD 0,723 i varijancu σ^2 od 0,9523 te za 2024. godinu prosječnom ocjenom 9,98 uz SD 0,612 i varijancu σ^2 od 0,375. Time je projicirano poboljšanje za 23,3%
3. ***Pouzdanost tehnologije i kompatibilnost s drugim sustavima*** uvelike zavisi od investicijskih mogućnosti s obzirom na to da su računalni sustavi osjetljivi na zlonamjerne radnje posebice ako su povezani nesigurnim vezama. Poznavatelji su ovaj element za 2019. godinu ocijenili prosječnom ocjenom 7,55 uz SD 0,928 i varijancu σ^2 od 0,863 te za 2024. godinu prosječnom ocjenom 9,28 uz SD 0,749 i varijancu σ^2 od 0,562. Time je projicirano poboljšanje za 23,0%.
4. ***Informacijske tehnologije u međuorganizacijskim sustavima*** sastavni su dio željene korisničke podrške funkcioniranja CRM-a koje moraju biti kompatibilne. Poznavatelji su ovaj element za 2019. godinu ocijenili prosječnom ocjenom 7,52 uz SD 1,06295 i varijancu σ^2 od 1,13 te za 2024. godinu prosječnom ocjenom 9,37 uz SD 0,7697 i varijancu σ^2 od 0,593. Time je projicirano poboljšanje za 24,7%.
5. ***Zahtjevi za personaliziranije odnose hotela s gostom*** je razvojni element koji su poznavatelji za 2019. godinu ocijenili prosječnom ocjenom 7,62 uz SD 1,24781 i varijancu σ^2 od 1,19 te za 2024. godinu prosječnom ocjenom 9,12 uz SD 1,091 i varijancu σ^2 od 1,19. Time je projicirano poboljšanje za 19,6%.
6. ***Zahtjevi za personaliziranije odnose hotela s gostom*** je razvojni element koji su poznavatelji za aktualnu 2019. godinu ocijenili prosječnom ocjenom 77,78 uz SD 1,188 i varijancu σ^2 od 1,412 te za 2024. godinu prosječnom ocjenom 9,23 uz SD 0,778 i varijancu σ^2 od 0,606. Time je projicirano poboljšanje za 18,61%.
7. ***Financijski potencijali*** su element koji može biti i razvojni, ali i ograničavajući u slučajevima poremećaja na turističkim tržištima. Poznavatelji su ovaj element za aktualnu 2019. godinu ocijenili prosječnom ocjenom 7,64 uz SD 1,063 i varijancu σ^2 od 1,132 te za 2024. godinu prosječnom ocjenom 9,26 uz SD 0,8004 i varijancu σ^2 od 0,641. Time je projicirano poboljšanje za 21,14%.
8. ***Bruto domaći proizvod*** je element na koji hotelsko poduzeće djeluje tek posredno, ali koji je bitan kao pokazatelj smjera društvenog razvoja. Poznavatelji su ovaj element za 2019. godinu ocijenili prosječnom ocjenom 7,86 uz SD 1,1643 i varijancu σ^2 od 2,701 te za 2024.

godinu prosječnom ocjenom 9,30 uz SD 0,9936 i varijancu σ^2 od 0,988. Time je projicirano poboljšanje za 18,27%.

9. ***Razvoj tehnologije (inteligentni softveri, novi mobilni sustavi).*** ICT se razvija progresivno i teško je predvidjeti koje inovativne proizvode će u narednom petogodišnjem razdoblju proizvesti, ali zasigurno neće stagnirati. Poznavatelji su ovaj element za 2019. godinu ocijenili prosječnom ocjenom 7,74 uz SD 1,205 i varijancu σ^2 od 1,453 te za 2024. godinu prosječnom ocjenom 9,27 uz SD 0,8727 i varijancu σ^2 od 0,762. Time je projicirano poboljšanje za 19,72%.
10. ***Sustav unaprjeđenja kvalitete usluga*** djeluje posredno kao proizvod komuniciranja između gosta i hotela u sklopu unaprjeđenja njihova odnosa koji uključuje i kvalitetu usluge. Poznavatelji su ovaj element za 2019. godinu ocijenili prosječnom ocjenom 7,64 uz SD 1,2131 i varijancu σ^2 od 1,472 te za 2024. godinu prosječnom ocjenom 9,14 uz SD 1,1776 i varijancu σ^2 od 1,387. Time je projicirano poboljšanje za 19,63%.
11. ***Troškovi proizvodnje hotelijerske usluge*** ogledaju se kroz smanjenje troškova rasvjete i energenata, marketinga i očuvanja okoliša. Poznavatelji su ovaj element za 2019. godinu ocijenili prosječnom ocjenom 7,65 uz SD 1,2283 i varijancu σ^2 od 1,509 te za 2024. godinu prosječnom ocjenom 9,27 uz SD 0,7661 i varijancu σ^2 od 0,587. Time je projicirano poboljšanje za 21,11%.
12. ***Hotelska etika i društvena odgovornost*** je element koji se razvija usporedo s razvojem odnosa između gosta i hotela. Poznavatelji su ovaj element za 2019. godinu ocijenili prosječnom ocjenom 7,80 uz SD 1,1191 i varijancu σ^2 od 1,253 te za 2024. godinu prosječnom ocjenom 9,44 uz SD 0,7497 i varijancu σ^2 od 0,560. Time je projicirano poboljšanje za 20,98%.
13. ***Hotelski imidž*** je u funkciji CRM-a na način da svaki hotel koji želi biti prepoznatljiv jednostavno mora na neki način upravljati odnosima s gostima neovisno o tme kakve će benefite imati od toga. Poznavatelji su ovaj element za 2019. godinu ocijenili prosječnom ocjenom 7,68 uz SD 1,2564 i varijancu σ^2 od 1,579 te za 2024. godinu prosječnom ocjenom 9,24 uz SD 0,8302 i varijancu σ^2 od 0,689. Time je projicirano poboljšanje za 20,26%.
14. ***Hotelska kultura*** je element koji se treba neprestano razvijati, čuvati i nadograđivati sukladno promjenama u društvu i gospodarstvu. Poznavatelji su ovaj element za 2019. godinu ocijenili prosječnom ocjenom 7,61 uz SD 1,058 i varijancu σ^2 od 1,119 te za 2024. godinu prosječnom ocjenom 9,26 uz SD 0,6825 i varijancu σ^2 od 0,466. Time je projicirano poboljšanje za 21,61%.

Tablica 104. Vrednovanje elemenata razvoja CRM-a

VREDNOVANJE ELEMENATA RAZVOJA CRM-a		Input Y_{it}		Prirast
		2019.	2024.	Δy_i, 2024
1.	Ljudski potencijali – spremnost prihvaćanja i korištenja CRM-a	7,58	9,53	1,94
2.	ICT infrastruktura	7,61	9,38	1,77
3.	Pouzdanost tehnologije i kompatibilnost s drugim sustavima	7,55	9,28	1,74
4.	Informacijske tehnologije u međuorganizacijskim sustavima	7,52	9,37	1,86
5.	Zahtjevi za personaliziranije odnose hotela s gostom	7,62	9,12	1,49
6.	Zahtjevi za personaliziranije odnose gosta s hotelom	7,78	9,23	1,45
7.	Financijski potencijali	7,64	9,26	1,62
8.	Bruto domaći proizvod	7,86	9,30	1,44
9.	Razvoj tehnologije (inteligentni softveri, novi mobilni sustavi)	7,74	9,27	1,53
10.	Sustav unaprjeđenja kvalitete usluga	7,64	9,14	1,50
11.	Troškovi proizvodnje hotelijerske usluge	7,65	9,27	1,62
12.	Hotelska etika i društvena odgovornost	7,80	9,44	1,64
13.	Hotelski imidž	7,68	9,24	1,56
14.	Hotelska kultura	7,61	9,26	1,65

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

U tablici 104. su sistematizirane dobivene prosječne ocjene svakog pojedinog razvojnog elementa u promatranom trenutku (2019. godina) i njegovoj projekciji za 2024. godinu kao polazišta za formiranje modela rasta i razvoja primjene ICT-a u hotelskoj industriji.

1.33 Model razvoja primjene ICT-a u hotelskoj industriji

Da bi se primjereno kvantificirao i ispitao rast razvojnih elemenata CRM-a u hotelskim poduzećima uporabljena je matrica rasta koja tretira strukturne odnose razvojnih elemenata na specifičan način (Stojanović, 1990). Ta se specifičnost ogleda u činjenici da su razvojni elementi međuovisni i da praćenje njihove važnosti u razvojnom potencijalu treba promatrati simultano preko direktnih i indirektnih stopa rasta. Nakon analize osnovnih značajka matrice rasta i formuliranja modela moguće je primijeniti vrijednosti elemenata modela razvoja te utvrditi matricu rasta tog modela.

Iskustveno utemeljena pretpostavka je da se razvojni potencijal unaprjeđenja upravljanja odnosa s gostima sastoji od *n* međusobno ovisnih elemenata. S y_{it} i $yi_{,t-1}$ označit će se vrijednost (npr. kao input) i-tog razvojnog elementa (i = 1, …, n) u razdoblju t i t-1. Prirast vrijednosti inputa i-tog elementa razvojnog potencijala unaprjeđenja CRM-a:

$$\Delta y_{it} = y_{it} - \Delta y_{it-1} \quad (1)$$

Indirektna stopa rasta i-tog elementa razvojnog potencijala unaprjeđenja CRM-a u odnosu na j-ti, definira se kao odnos prirasta inputa i-tog elementa razvojnog potencijala CRM-a, Δy_{it}, i vrijednosti inputa j-tog elementa razvojnog potencijala CRM-a razdoblju t, odnosno:

$$r_{ijt} = y_{it} / y_{jt} \; i,j = 1, \ldots., n. \; Y_{jt} \neq 0. \qquad (2)$$

Temeljem podataka iz tablice 104. moguće je odrediti matricu rasta po elementima modela razvojnoga potencijala CRM-a u odnosu na tekuće i buduće vrijednosti u razdoblju 2019. – 2024. godina.

Matrica rasta = vektor rasta × vektor recipročnih vrijednosti, odnosno:

$$R_{2024} = \Delta y'_{2024} \cdot \frac{1}{y_{2024}} \qquad (3)$$

$$R_{2024} = \begin{bmatrix} 7{,}58 \\ 7{,}61 \\ 7{,}55 \\ 7{,}52 \\ 7{,}62 \\ 7{,}78 \\ 7{,}64 \\ 7{,}86 \\ 7{,}74 \\ 7{,}64 \\ 7{,}65 \\ 7{,}80 \\ 7{,}68 \\ 7{,}61 \end{bmatrix} \cdot \left[\frac{1}{9{,}53}, \frac{1}{9{,}38}, \frac{1}{9{,}28}, \frac{1}{9{,}37}, \frac{1}{9{,}12}, \frac{1}{9{,}23}, \frac{1}{9{,}26}, \frac{1}{9{,}3}, \frac{1}{9{,}27}, \frac{1}{9{,}14}, \frac{1}{9{,}27}, \frac{1}{9{,}44}, \frac{1}{9{,}24}, \frac{1}{9{,}26'} \right]$$

Umnožak vanjskog vektora Δy'2024 i 1/y2024 određuje matricu razvojnog potencijala CRM-a u odnosu na tekuće vrijednosti:

Tablica 105. Matrica razvoja CRM-a u hotelskoj industriji

7,6/9,5	7,6/9,4	7,6/9,3	7,6/9,4	7,6/9,1	7,6/9,2	7,6/9,3	7,6/9,3	7,6/9,3	7,6/9,1	7,6/9,3	7,6/9,4	7,6/9,2	7,6/9,3
7,6/9,5	7,6/9,4	7,6/9,3	7,6/9,4	7,6/9,1	7,6/9,2	7,6/9,3	7,6/9,3	7,6/9,3	7,6/9,1	7,6/9,3	7,6/9,4	7,6/9,2	7,6/9,3
7,6/9,5	7,6/9,4	7,6/9,3	7,6/9,4	7,6/9,1	7,6/9,2	7,6/9,3	7,6/9,3	7,6/9,3	7,6/9,1	7,6/9,3	7,6/9,4	7,6/9,2	7,6/9,3
7,8/9,5	7,8/9,4	7,8/9,3	7,8/9,4	7,8/9,1	7,8/9,2	7,8/9,3	7,8/9,3	7,8/9,3	7,8/9,1	7,8/9,3	7,8/9,4	7,8/9,2	7,8/9,3
7,6/9,5	7,6/9,4	7,6/9,3	7,6/9,4	7,6/9,1	7,6/9,2	7,6/9,3	7,6/9,3	7,6/9,3	7,6/9,1	7,6/9,3	7,6/9,4	7,6/9,2	7,6/9,3
7,8/9,5	7,8/9,4	7,8/9,3	7,8/9,4	7,8/9,1	7,8/9,2	7,8,9,3	7,8/9,3	7,8/9,3	7,8/9,1	7,8/9,3	7,8/9,4	7,8/9,2	7,8/9,3
7,6/9,5	7,6/9,4	7,6/9,3	7,6/9,4	7,6/9,1	7,6/9,2	7,6/9,3	7,6/9,3	7,6/9,3	7,6/9,1	7,6/9,3	7,6/9,4	7,6/9,2	7,6/9,3
7,9/9,5	7,9/9,4	7,9/9,3	7,9/9,4	7,9/9,1	7,9/9,2	7,9/9,3	7,9/9,3	7,9/9,3	7,9/9,1	7,9/9,3	7,9/9,4	7,9/9,2	7,9/9,3
7,7/9,5	7,7/9,4	7,7/9,3	7,7/9,4	7,7/9,1	7,7/9,2	7,7/9,3	7,7/9,3	7,7/9,3	7,7/9,1	7,7/9,3	7,7/9,4	7,7/9,2	7,7/9,3
7,6/9,5	7,6/9,4	7,6/9,3	7,6/9,4	7,6/9,1	7,6/9,2	7,6/9,3	7,6/9,3	7,6/9,3	7,6/9,1	7,6/9,3	7,6/9,4	7,6/9,2	7,6/9,3
7,7/9,5	7,7/9,4	7,7/9,3	7,7/9,4	7,7/9,1	7,7/9,2	7,7/9,3	7,7/9,3	7,7/9,3	7,7/9,1	7,7/9,3	7,7/9,4	7,7/9,2	7,7/9,3
7,8/9,5	7,8/9,4	7,8/9,3	7,8/9,4	7,8/9,1	7,8/9,2	7,8/9,3	7,8/9,3	7,8/9,3	7,8/9,1	7,8/9,3	7,8/9,4	7,8/9,2	7,8/9,3
7,7/9,5	7,7/9,5	7,7/9,3	7,7/9,4	7,7/9,1	7,7/9,2	7,7/9,3	7,7/9,3	7,7/9,3	7,7/9,1	7,7/9,3	7,7/9,4	7,7/9,2	7,7/9,3
7,6/9,5	7,6/9,4	7,6/9,3	7,6/9,4	7,6/9,1	7,6/9,2	7,6/9,3	7,6/9,3	7,6/9,3	7,6/9,1	7,6/9,3	7,6/9,4	7,6/9,2	7,6/9,3

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Iz matrice se izračunavaju stope rasta elemenata razvoja CRM-a u hotelskoj industriji kako je to predočeno narednom tablicom.

Tablica 106. Stope rasta razvojnih elemenata CRM-a u hotelskoj industriji

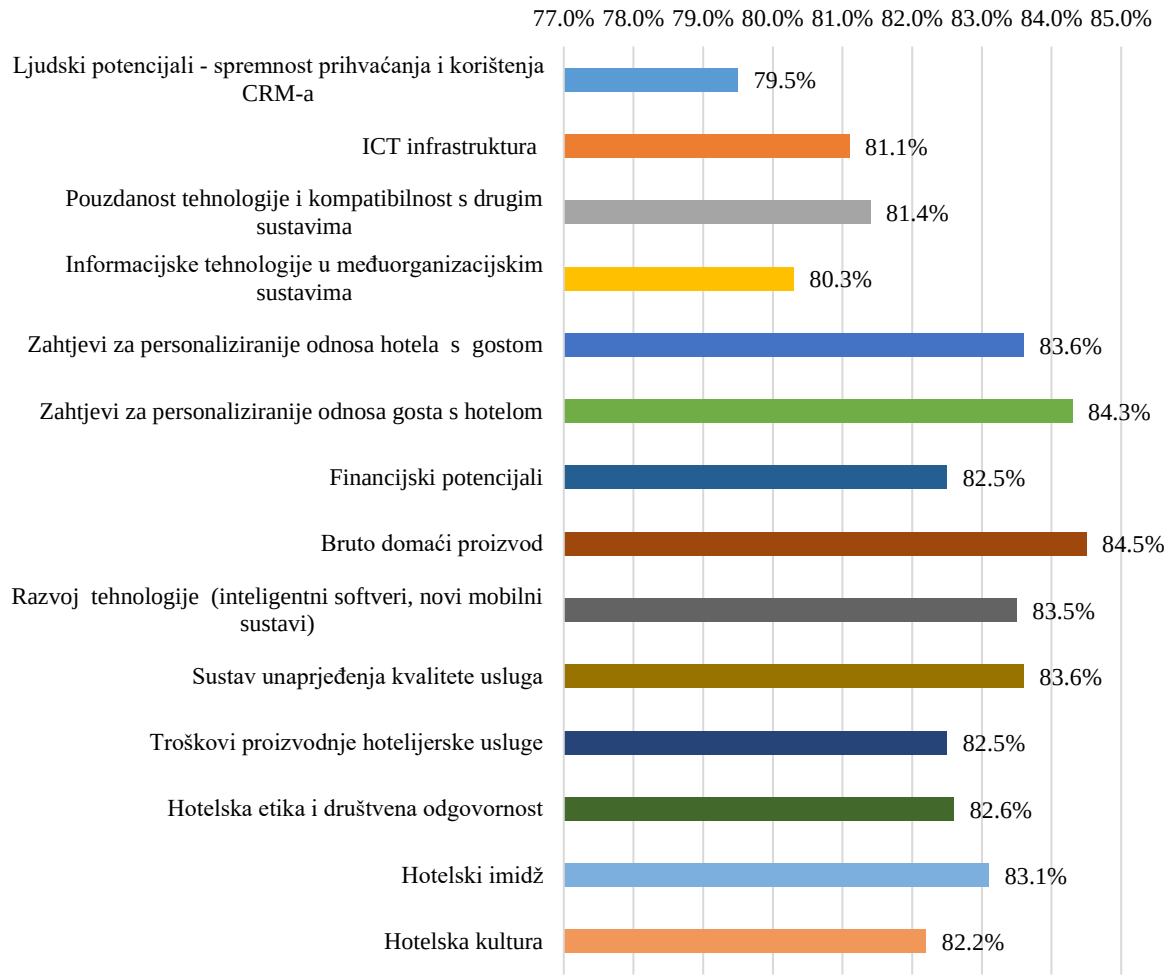
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	79,5	80,8	81,7	80,9	83,1	82,1	81,9	81,5	81,8	82,9	81,8	80,3	82,0	81,9
2	79,9	81,1	82,0	81,2	83,4	82,4	82,2	81,8	82,1	83,3	82,1	80,6	82,4	82,2
3	79,2	80,5	81,4	80,6	82,8	81,8	81,5	81,2	81,4	82,6	81,4	80,0	81,7	81,5
4	78,9	80,2	81,0	80,3	82,5	81,5	81,2	80,9	81,1	82,3	81,1	79,7	81,4	81,2
5	80,0	81,2	82,1	81,3	83,6	82,6	82,3	81,9	82,2	83,4	82,2	80,7	82,5	82,3
6	81,6	82,9	83,8	83,0	85,3	84,3	84,0	83,7	83,9	85,1	83,9	82,4	84,2	84,0
7	80,2	81,4	82,3	81,5	83,8	82,8	82,5	82,2	82,4	83,6	82,4	80,9	82,7	82,5
8	82,5	83,8	84,7	83,9	86,2	85,2	84,9	84,5	84,8	86,0	84,8	83,3	85,1	84,9
9	81,2	82,5	83,4	82,6	84,9	83,9	83,6	83,2	83,5	84,7	83,5	82,0	83,8	83,6
10	80,2	81,4	82,3	81,5	83,8	82,8	82,5	82,2	82,4	83,6	82,4	80,9	82,7	82,5
11	80,3	81,6	82,4	81,6	83,9	82,9	82,6	82,3	82,5	83,7	82,5	81,0	82,8	82,6
12	81,8	83,2	84,1	83,2	85,5	84,5	84,2	83,9	84,1	85,3	84,1	82,6	84,4	84,2
12	80,6	81,9	82,8	82,0	84,2	83,2	82,9	82,6	82,8	84,0	82,8	81,4	83,1	82,9
14	79,9	81,1	82,0	81,2	83,4	82,4	82,2	81,8	82,1	83,3	82,1	80,6	82,4	82,2

Izvor: obrada autora u IBM SPSS Statisticsu prema podatcima anketnog upitnika

Direktne stope rasta pokazuju da se rast jednoga elementa događa neovisno od rasta drugih. Međutim, kada se promatraju indirektne stope rasta, tj. rast i-tog elementa u odnosu na j-ti (i, j = 1, ..., n), moguće je odrediti strukturu rasta elemenata i izraziti sve odnose preko matrice rasta u ukupnom sustavu. Istovremenim promatranjem direktnih i indirektnih stopa rasta mogu se sagledavati promjene intenziteta rasta pojedinih elemenata i njihove međusobne odnose odnose.

Provedenim istraživanjem i vrednovanjem razvojnog potencijala CRM-a hotelske industrije dobivene su direktne stope rasta pojedinih razvojnih elemenata koje se predočavaju narednim grafikonom.

Grafikon 18. Direktne stope razvoja elemenata CRM-a hotelske industrije



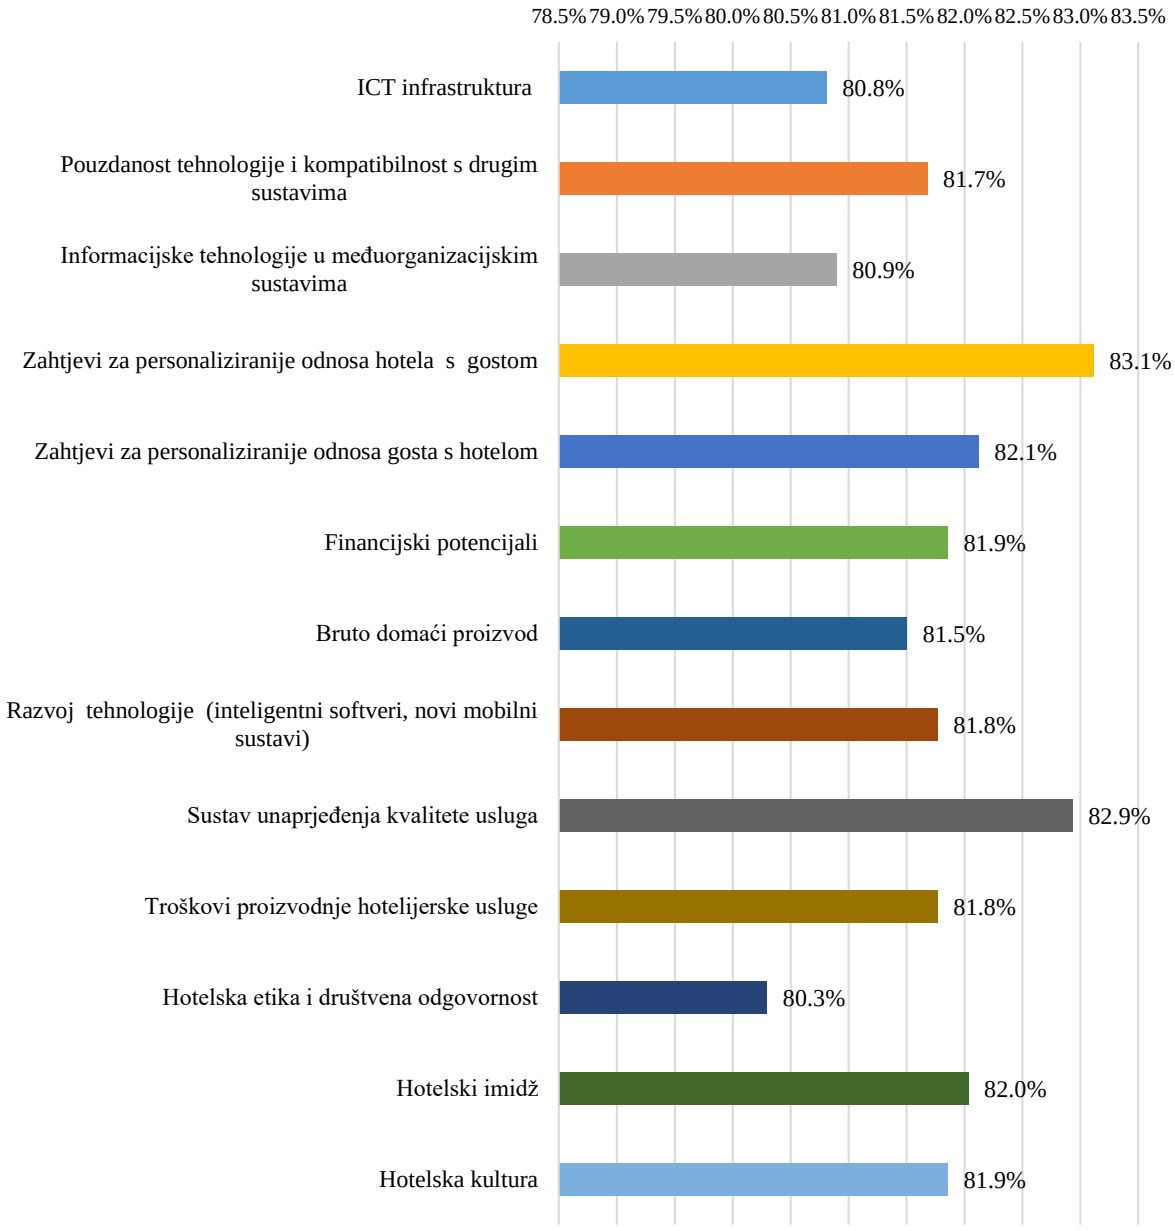
Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Iako se radi o malim razlikama, uočljivo je kako bi promatrajući direktne stope razvoja najveći utjecaj na cjelokupni sustav hotelske industrije trebao imati bruto nacionalni proizvod (84,5%), a tek potom zahtjevi za personaliziranije odnose gosta s hotelom (84,3%) i hotela s gostom (83,6%).

Usporavajući faktor rasta i razvoja CRM-a u hotelskoj industriji nalazi se u ljudskim potencijalima, odnosno njihovoj spremnosti da prihvate i koriste CRM (79,5%).

Temeljem podataka iz tablice 104. mogu se predvidjeti i indirektne stope rasta između pojedinih elemenata razvojnog potencijala CRM-a. U nastavku analizira se kako ostali elementi razvoja djeluju na element ljudskih potencijala, odnosno njihove spremnosti prihvaćanja i korištenja CRM-a što se predočava narednim grafikonom.

Grafikon 19. Indirektne stope rasta razvoje ljudskih potencijala u odnosu na druge razvojne elemente



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Uspoređujući spremnost zaposlenika da prihvate i koriste CRM na razvojni potencijal CRM-a u hotelskoj industriji zamjetna je stopa rasta zahtjeva za personaliziranije odnose hotela s gostom (83,1%) kao i sustava za unaprjeđenje kvalitete usluge (82,9%) što ukazuje na činjenicu

da su ti elementi pod snažnim utjecajem ljudskih potencijala i njihove spremnosti da prihvati CRM. Usporedba drugih elemenata moguća je po istom načelu, ali se zbog racionalizacije prostora izostavlja.

1.34 Zadovoljstvo postojećim sustavom ICT-a u hotelu

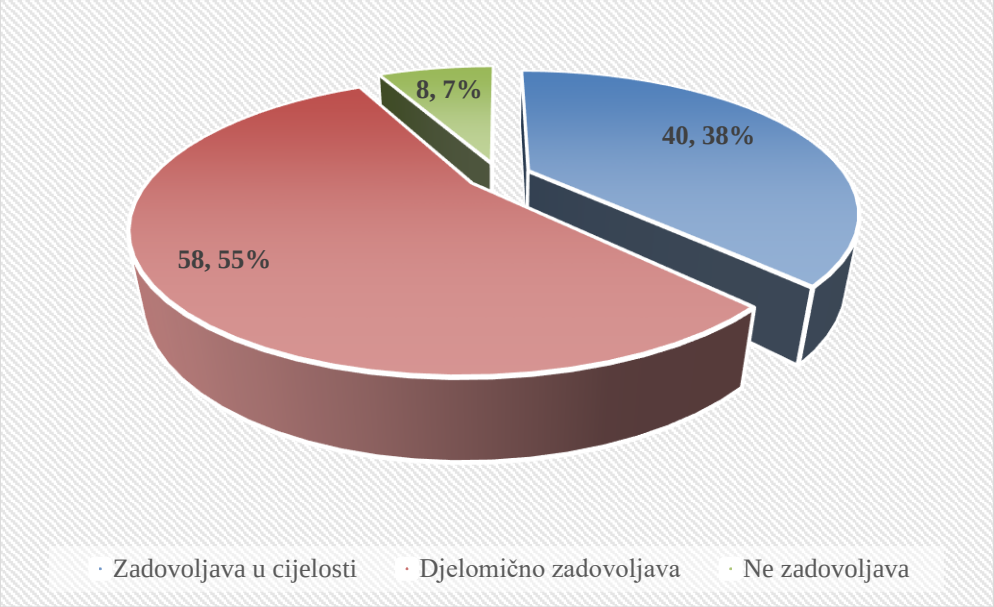
Od ispitanika se tražilo da se izjasne zadovoljava li postojeći sustav ICT-a njihove potrebe i očekivanja od suvremenog informatičkog sustava. Ispitanicima su ponuđeni odgovori: a) zadovoljava u cijelosti, b) djelomično zadovoljava i c) ne zadovoljava.

Prikupljeni su odgovori kako slijedi:

- zadovoljava u cijelosti – 40 ispitanika (37,37%)
- djelomično zadovoljava – 58 ispitanika (54,7%) i
- ne zadovoljava – 8 ispitanika (7,5%).

Vizualno se frekvencija i distribucija prikupljenih odgovora predočava narednim grafikonom.

Grafikon 20. Zadovoljstvo postojećim sustavom ICT-a u hotelu



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Da samo djelomično ili uopće ne zadovoljava potrebe hotelskog menedžmenta i njihova očekivanja od ICT-a, smatra visokih 62,2% ispitanika što je podatak koji ne zadovoljava

potrebe suvremenog turizma. Tomu svakako doprinosi i neravnomjeran opći razvoj Republike Hrvatske koji se odnosi i na IT infrastrukturu posebice na otocima i kontinentalnim područjima izvan glavnih centara. To je svakako otežavajuća okolnost za učinkovito upravljanje odnosima s gostima.

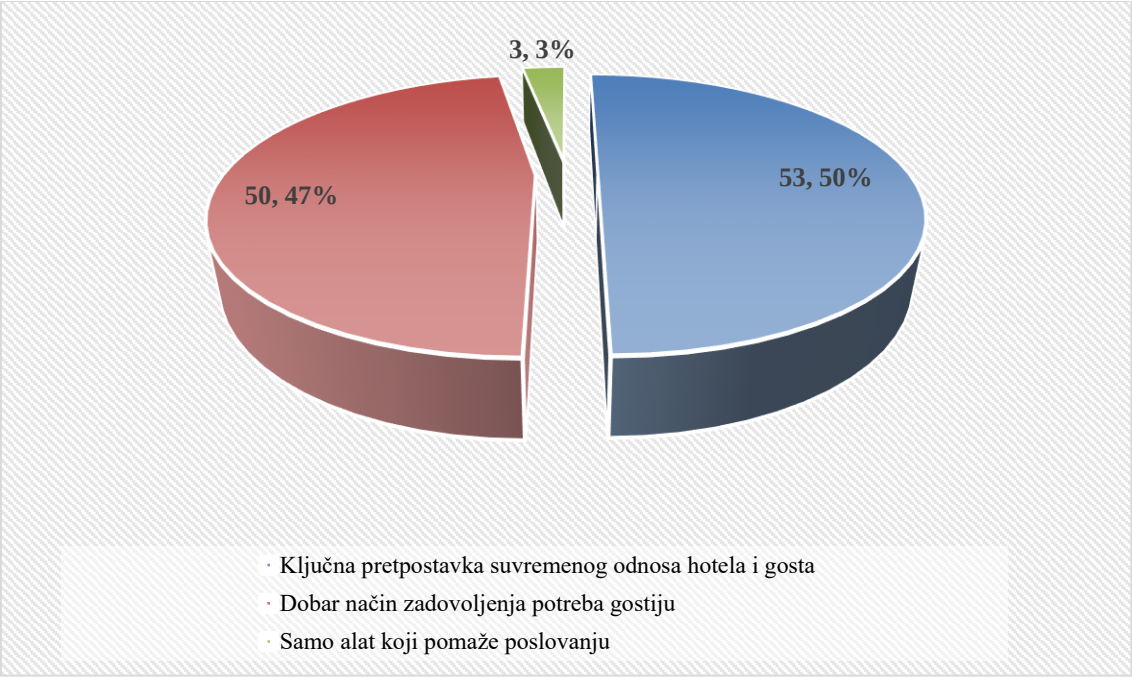
1.35 Percepcija značaja informatičkog sustava CRM-a

Od ispitanika se tražilo da se izjasne o važnosti korištenja informatičkog sustava CRM-a kao sastavnice suvremenog poslovanja hotelskog poduzeća. Ispitanicima su ponuđeni odgovori: a) ključna pretpostavka suvremenog odnosa hotela i gosta, b) dobar način zadovoljenja potreba gostiju i c) samo alat koji pomaže poslovanju. Prikupljeni su odgovori kako slijedi:

- ključna pretpostavka suvremenog odnosa hotela i gosta – 53 ispitanika (50,0%)
- dobar način zadovoljenja potreba gostiju – 50 ispitanika (47,2%) i
- samo alat koji pomaže poslovanju – 3 ispitanika (2,8%).

Vizualno se frekvencija i distribucija prikupljenih odgovora predočava narednim grafikonom.

Grafikon 21. Percepcija značaja informatičkog CRM-a u hotelu



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Polovina ispitanika smatra kako je uporaba informatičkog CRM-a u hotelskoj industriji ključna pretpostavka suvremenog odnosa hotela i gosta. Druga polovina ima pak mišljenje kako je

CRM samo dobar način zadovoljenja potreba gostiju (47,2%) ili samo alat koji pomaže poslovanju.

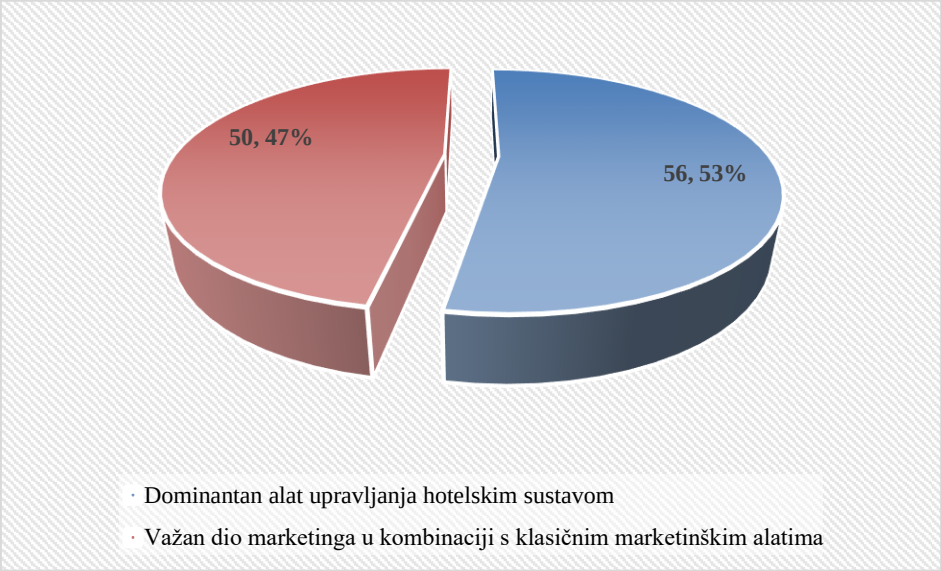
1.36 Budućnost CRM-a u hotelijerstvu

Kakvu će ulogu imati informatički CRM u nekom budućem modelu učinkovitog kreiranja odnosa s gostima u hotelijerstvu glasilo je pitanje na koje su ponuđena tri moguća odgovora: a) dominantan alat upravljanja hotelskim sustavom, b) važan dio marketinga u kombinaciji s klasičnim marketinškim alatima i c) samo nužan alat za održavanje koraka s novim tehnologijama. Prikupljeni su odgovori kako slijedi:

- dominantan alat upravljanja hotelskim sustavom – 56 ispitanika (52,8%)
- važan dio marketinga u kombinaciji s klasičnim marketinškim alatima – 50 ispitanika (47,2%).

Nitko od ispitanika nije smatrao da će sustav CRM u budućnosti biti samo nužan alat za održavanje koraka s novim tehnologijama. Vizualno se frekvencija i distribucija prikupljenih odgovora predočava narednim grafikonom.

Grafikon 22. Budućnost CRM-a u hotelijerstvu



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Nešto više od polovine ispitanika smatra kako će u narednom razdoblju informatički CRM postati dominantan alat upravljanja hotelskim sustavom dok ostali smatraju kako će on postati samo važan dio marketinga u kombinaciji s klasičnim marketinškim alatima.

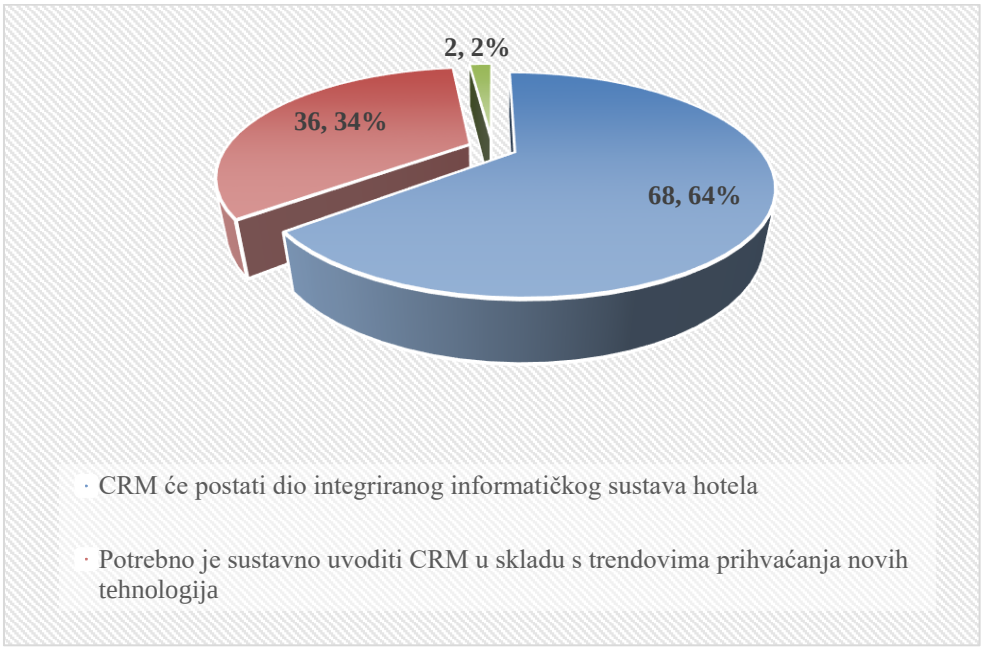
1.37 Stavovi poznavatelja o razvoju CRM-a

Od ispitanika, dobrih poznavatelja tematike CRM-a u hotelskoj industriji, tražilo se njihovo stručno mišljenje o daljem razvoju CRM-a. U tom smislu ponuđeni su im sljedeći mogući odgovori: a) CRM će postati dio integriranog informatičkog sustava hotela, b) potrebno je sustavno uvoditi CRM u skladu s trendovima prihvaćanja novih tehnologija i c) treba prepustiti stvar trendovima u hotelijerstvu bez posebnog inzistiranja na CRM-u. Prikupljeni su odgovori kako slijedi:

- CRM će postati dio integriranog informatičkog sustava hotela – 68 ispitanika (64,2%)
- potrebno je sustavno uvoditi CRM u skladu s trendovima prihvaćanja novih tehnologija – 36 ispitanika (34,0%)
- treba prepustiti stvar trendovima u hotelijerstvu bez posebnog inzistiranja na CRM-u – 2 ispitanika (1,9%).

Vizualno se frekvencija i distribucija prikupljenih odgovora predočava narednim grafikonom:

Grafikon 23. Stavovi ispitanika o razvoju CRM-a



Izvor: obrada autora u MS Excelu prema podatcima anketnog upitnika

Većina ispitanika smatra da CRM treba postati sastavni dio integriranog informatičkog sustava u hotelu dok je nešto manje od trećine ispitanika oprezno pri prihvaćanju novih rješenja i smatra da njihovo uvođenje treba biti postupno. Da ne treba inzistirati na novim rješenjima, smatraju svega dva ispitanika.

1.38 Rasprava

Statistička obrada i analiza anketnog upitnika, kojim su se nastojale spoznati operativne efikasnosti i inovativnosti primjene ICT tehnologije u poslovanju hotelskih poduzeća u Republici Hrvatskoj, rezultirala je nizom zaključaka temeljenih na statističkim pokazateljima. Pri odabiru uzorka ispitanika nastojalo se obuhvatiti poznavatelje koji mogu reprezentirati veći dio hrvatske hotelske industrije.

Pretpostavljalo se da će stavovi ispitanika s obzirom na njihovu poziciju u hotelu (direktor hotela, direktor marketinga i šef recepcije) imati bliske stavove o razmatranoj problematici. Pokazalo se da je to u većini slučajeva točno s time da se pozicija „direktor marketinga“ isticala pri dodjeljivanju viših ocjena što je vjerojatno rezultat njegove profesionalne angažiranosti, a time i boljeg poznavanja materije.

Sukladno tomu nisu se pokazala veća odstupanja pri ocjenjivanju s obzirom na starosnu dob, školsku spremu i radni staž ispitanika što je mjereno prosječnim ocjenama i standardnim odstupanjima.

Veće razlike u ocjenjivanju uočavale su se kod ispitanika promatrano sa stajališta lokacije njihova hotela, vrste, veličine i namjene. Najbolje ocjene i procjene dobivene su od specijaliziranih hotela (kongres, sport i zabava, zdravlje i *wellness*) što je razumljivo jer oni imaju ciljanu klijentelu, a time i posebne odnose s njima. Nadalje u primjeni CRM-a ističu se hoteli u priobalju i gradovima, dok su za upravljanje odnosa s gostima korištenjem informacijske tehnologije zakinuti hoteli na otocima i kontinentu zbog nedostatne informacijske infrastrukture.

Sa svrhom dobivanja što egzaktnijih stavova ispitanika korištena je ljestvica ocjenjivanja raspona 1 – 10. Sporadičan je bio broj iskazanih ocjena manjih od 6 te ocjene 10, dok se većina ocjena kretala između 7 i 9. Preneseno na školski sustav ocjenjivanja (1 – 5), radi se o ocjeni vrlo dobar prema odličnom.

Ako se kao nulto istraživanje primjene informacijske tehnologije u hotelima uzme 2002. godina (Galičić & Cerovac, Menadžeri hotela i informacijska tehnologija, 2004), tada se bilježi porast prosječnih ocjena za 1 što je znatan pomak kada su u pitanju stavovi poznavatelja korištenja ICT-a u hrvatskim hotelima.

Poseban naglasak provedene analize stavlja se na ocjenjivanje razvojnih elementa CRM-a u hotelskoj industriji. Odabrani su elementi iz hotelskog sustava kao i oni iz bližeg ili šireg okruženja koji posredno ili neposredno imaju svoj utjecaj na razvoju upravljanja odnosima s gostima. Prosjek svih prosječnih ocjena za godinu u kojoj je provođeno istraživanje iznosio je 7,666. Projicirani prosjek za 2024. godinu, dakle u petogodišnjoj perspektivi, iznosio je 9,292 što je povećanje od 21,21% i koje se približava najvišoj ocjeni.

Takav način razmišljanja ispitanika nedvojbeno ukazuje na njihovo povjerenje u razvoj i unaprjeđenje sustava informatičkog CRM-a ili već aktualnog SCRM-a ili nekog budućeg XCRM-a koji se zbog progresivnog razvoja ICT-a može očekivati.

Nadalje, važni su i odgovori koji opisuju postojeće stanje ICT-a u odnosu na poslovne potrebe hotelijera, gdje njih 37,7% smatra da ih ono u cijelosti zadovoljava. To se može komentirati kao pozitivan iskorak ako se usporedi s istraživanjima iz 2002. godine kada je takvo zadovoljstvo iznosilo svega 7%.

Isto tako, kada se uspoređuju stavovi hotelskih menadžera u razmaku od 18 godina, tada je mišljenje o informatičkom sustavu CRM-u u provedenom istraživanju 50% ispitanika smatra da je on ključna pretpostavka suvremenog odnosa hotela i gosta, dok je u nultom istraživanju taj postotak bio 15%.

Razmišljanja o učinkovitosti CRM-a i njegovoj budućnosti u hotelijerstvu su neupitna, menadžeri su prihvatili njegovo korištenje u svakodnevnom poslovanju kao nešto uobičajeno i brzo se prilagođavaju pristupu podatcima s mobilnih uređaja i upravljanjem na daljinu.

ZAKLJUČAK

Istraživanje teme ***Strateški značaj informacijskih tehnologija u unaprjeđenju konkurentske sposobnosti poduzeća*** obuhvaća široko područje koje uključuje korištenje dostignutih spoznaja iz područja informatike, organizacije poslovanja, strateškog i upravljačkog menadžmenta, marketinga te hotelijerstva kao korisnika i proizvođača usluga. Sukladno navedenom tekao je i proces prikupljanja domaće i strane stručne i znanstvene literature, konzultacija s relevantnim čimbenicima i autoritetima iz područja upravljanja hotelima i korištenja informatičko-komunikacijske tehnologije u poslovne svrhe, aktivno korištenje web prostora u smislu proučavanja objavljenih radova i istraživanja vezanih za temu doktorskog rada kao i tematski važnih blogova, osvrta i komentara.

Informacijsko-komunikacijska tehnologija učinila je hotelsku industriju ovisnom o internetu, dovela je do pojave pametnih hotela, ubrzala je procese rezervacija i prodaje, reducirala broj zaposlenih u administraciji, reducirala potrošnju vode, struje i energenata, unaprijedila pravovremenost nabave namirnica i potrošnog materijala, unaprijedila marketing, odnose s gostima, sigurnost i zaštitu te još cijeli niz pogodnosti i olakšanja zaposlenicima u obavljanju svakodnevnih poslova. Ipak, ICT je unatoč nabrojenome samo olakotno sredstvo i koristan alat, dok su hotelijer, recepcionar, kuhar ili sobar i nadalje ostali temeljni nosioci proizvodnje hotelske usluge.

Istraživanjem teme rada dostignuti su uvodno zadani ciljevi istraživanja. Opća hipoteza istraživanja o mjestu i ulozi informacijske tehnologije u poslovnoj strategiji poduzeća potvrđuje se u svakodnevnom poslovanju svakog hotelskog poduzeća kojim održava svoje poslovanje i ostvaruje konkurentnost. Argumentirano je dokazana važnost strateškog promišljanja o stalnom razvoju informacijskog sustava te uvođenje novih informatičkih tehnologija u hotelsko poslovanje postaje bitan sastavni dio poslovne koncepcije i strategije svakog poduzeća.

Zadatci postavljeni pred istraživača ispunjeni su tijekom provedbe statističke analize kada su argumentirano izvedeni zaključci o elementima integriranih komunikacijskih usluga u hotelu, funkcijama sustava CRM-a, korisničke podrške sustava CRM-a, razvojnih elemenata CRM-a te postojećim i nekim budućim ulogama upravljanja odnosima s gostima.

Pomoćne hipoteze dokazivane su sukladno poglavljima rada prema kojima su postavljene te argumentirano obrazložene.

Iz opisanog modela projekcije razvojnih elemenata upravljanja odnosima s gostima zaključuje se kako uspješno i racionalno upravljanje sustavom odnosa s gostima i potencijalnim gostima zahtijeva sagledavanje, utvrđivanje i primjereno vrednovanje svih elemenata koji izravno ili neizravno utječu na njegovo funkcioniranje. Sinergijski učinak tih elemenata i realno formulirana strategija korištenja informacijske i računalne tehnologije u hotelskom poslovanju rezultirat će brojnim pozitivnim učincima među kojima su najvažniji: unaprjeđenje kvalitete hotelske usluge, smanjenje troškova proizvodnje hotelske usluge, personalizirana interakcija hotel – gost te očuvanje i unapređenje hotelskog brenda.

Primjena analiziranog modela rasta mogla bi imati za cilj poboljšanje uspješnosti te osiguranje rasta i razvoja informacijskih tehnologija u funkciji unapređenja konkurentske sposobnosti hotelskog poduzeća. Takvo razmatranje pridonosi potpunijem razumijevanju odnosa između elemenata (aktivnosti), njihova koordiniranja i boljeg programiranja u budućnosti. Model pokazuje da u budućnosti samo adekvatno izgrađen, optimalno strukturiran i organiziran sustav integriranih informacijsko-komunikacijskih usluga može na temelju sinergijskog djelovanja svih relevantnih elemenata utjecati na ukupni razvoj pružanja usluga u hotelskom poduzeću kao i hotelske industrije općenito.

Zaključci i doprinosi koji proizlaze iz dijela istraživanja u kojem se analizirao učinak društvenih medija na upravljanje odnosima s kupcima mogu se sažeto svesti na sljedeće:

Prvo, istraživanje provedeno u sklopu doktorskog rada nadovezuje se na aktualne spoznaje o SCRM strategiji u hotelskoj industriji na način da doprinosi razvoju teorije marketinga odnosa istraživanjem antecedenta i ishoda angažiranja gosta na društvenim medijskim platformama.

Drugo, ali ne i manje važno, prepoznaje angažman gosta kao kritični čimbenik uspjeha i za gosta i za hotelsko poduzeće i njegov brend čime se dodaje vrijednost teoriji marketinške komunikacije, ponašanju na društvenim mrežama putem interneta i teoriji angažmana.

Treće, ovo istraživanje pridonosi evoluciji hotelijerstava nadopunjavanjem istraživanja CRM-a u obliku SCRM-a, opsežnom analizom i uključivanjem teorija iz drugih disciplina poput upravljanja znanjem i informacijskim tehnologijama.

Iako znanstvena i stručna literatura nudi različita tumačenja prirode CRM-a, provedenim je istraživanjem moguće izdvojiti pet glavnih viđenja CRM-a:

- CRM kao proces. CRM je makroproces koji obuhvaća sve aktivnosti za dugoročno, profitabilno i uzajamno kreiranje povoljnih odnosa s klijentima. Iz perspektive hotelskog

poduzeća, to je postupak ograničen na upravljanje interakcijama s gostima radi uspostavljanja i održavanja trajnih odnosa.

- CRM kao strategija. Hotelska bi poduzeća trebala osmisliti i prioritetno uložiti sve resurse u izgradnju odnosa i održavanje vrijednosti koja se stvara iz tih odnosa.
- CRM kao filozofija. Lojalnost gostiju, a time i profitabilnost, zahtijeva kontinuirano razumijevanje potreba gosta u razvoju za pružanje najbolje usluge, odnosno njezine vrijednosti za novac.
- CRM kao sposobnost. Potencijalna, dodatna konkurentska prednost koju CRM može pružiti povezana je s kapacitetom okupljanja znanja o sadašnjim i potencijalnim gostima i djelovati na njih, na primjer proaktivno preoblikovanjem interakcija s kupcima.
- CRM kao tehnologija. Tehnologije za upravljanje znanjem i interakcijom, povezivanje svih funkcija u hotelu u nastojanju za kvalitetno upravljanje dugoročnim odnosima s gostima.

Zaključno se želi napomenuti da kao što marketing evoluira u korelaciji s razvojem informacijske tehnologije, tako bi i neka buduća istraživanja trebala uvažavati dostignute rezultate empirijskog dijela istraživanja kao bazična u vremenu i prostoru u kojem su nastala. Buduća istraživanja trebala bi generirati stavove gostiju i hotelijerskih zaposlenika koje bi omogućilo usporedbu s analiziranim stavovima hotelskih menadžera, sagledati razlike u stavovima s aspekta suprotstavljenih interesa, detektirati razlike u očekivanjima i spremnosti različitih dionika da sudjeluju i surađuju s ciljem stvaranja boljih rezultata uspješnosti odnosa.

Aplikativna vrijednost provedenog istraživanja ogleda se u tome da može poslužiti praktičarima, odnosno hotelskim menadžerima u razumijevanja višeslojne prirode CRM-a u poticanju angažiranosti gostiju kao kritične komponenta za postizanje financijske uspješnosti na temeljima lojalnosti gostiju hotelskom brendu. Hotelski menadžeri mogu na temelju praktičnog iskustva procijeniti funkcionalnost njihova postojećeg CRM-a kao i usklađenost s marketinškom strategijom upravljanja odnosa prema gostima. Oni mogu najbolje ocijeniti u kojoj mjeri njihovo upravljanje odnosima s gostima prati suvremene tehnološke inovacije i koliko su i jesu li potrebna ulaganja u novu CRM 2.0 strategiju. Nadalje, gosti više nisu pasivni potrošači usluga. Ovaj rad ukazuje na promjenu ponašanja gostiju u kontekstu hotelske industrije. Tehnologije društvenih medija unaprijedile su brojne kanale kojima gosti/potrošači mogu komunicirati i kreirati vlastiti doživljaj surađujući s pružateljima usluga.

Hotelski menadžeri nastoje imati vjerne goste koji se emocionalno povezuju s njihovim brendom. Angažirani gost je sukreator prodajne politike hotela i njegova vjernost brendu je u korelaciji s njegovim očekivanjima. Njegov angažman je njegovo potrošačko oruđe, a njegovo

zadovoljstvo je plod takve aktivnosti. Marketing hotelske industrije pak mora pronaći način da upravlja odnosom s angažiranim gostom kako bi zadržao svoju konkurentsku poziciju na tržištu. Jedan od učinkovitih alata je CRM.

Doprinos provedenog istraživanja u aplikativnom smislu podrazumijeva potvrdu iznesenih stavova menadžera hotelskih poduzeća o strateškoj važnosti informacijskih tehnologija u unaprjeđenju konkurentske sposobnosti hotelskih poduzeća. Naime, kada pojedinac (menadžer) visoko ocijeni ili procijeni neku od funkcija informacijske tehnologije, javlja se skepsa u pouzdanost takvog stava. Međutim kada relevantan uzorak menadžera potvrdi takvu ocjenu ili procjenu, tada to postaje argument u okvirima statističke pogreške, a pouzdanost takvog stava moguće je preispitivati samo novim istraživanjem, ali s odmakom vremena. Stoga se izneseni stavovi o operativnoj efikasnosti i inovativnosti primjene ICT tehnologije u poslovanju hotelskih poduzeća mogu koristiti kao predložak strateškom promišljanju, a time i polaznom argumentu pri formuliranju strategija te izrade taktičkih i operativnih planova poslovanja.

Znanstveni doprinos ogleda se u sustavnom pristupu i sveobuhvatnoj analizi učinkovitosti primjena informacijske i informatičke tehnologije kao modele pri stjecanju novih spoznaja o mogućnostima, izazovima i trendovima primjene informacijsko-komunikacijske tehnologije u hotelskom poslovanju. Nadalje, znanstveni se doprinos ogleda u znanstvenom pristupu izazovima novih tehnologija i njihovu utjecaju na život i poslovanje te njihovu razumijevanju i prihvaćanju u razvoju znanstvene misli o tehnologiji općenito.

Predstavljeni sistematizirani podatci i rezultati teorijskog i empirijskog istraživanja o ovom doktorskom radu mogu činiti polazište za neka nova znanstvena istraživanja, ali ujedno biti i svojevrstan *modus operandi* kako, gdje, kada i zašto koristiti informatičku tehnologiju, u kojem trenutku investirati u nove tehnologije i kako ih primijeniti u hotelskom poslovanju.

Očekivani doprinos ekonomskoj znanosti u teorijskom smislu proizlazi iz razvijanja znanstvenih spoznaja i misli o važnosti uvođenja i primjeni informacijskih tehnologija u poslovanju hotelskih poduzeća, posebice u operacijskom dijelu uspješnog menadžerskog odlučivanja kao i naglasak na upravljanje zadovoljstvom gostiju.

Očekivani doprinos ekonomskoj znanosti u aplikativnom smislu temelji se na predlaganju smjernica za buduće aktivnosti, poboljšanja i unaprjeđenje poslovanja hotelskih poduzeća u primjeni informacijske tehnologije, odnosno dala bi se projekcija određenih zaključaka uspostave i efikasnost modela CRM kao konkurentsko strateške okosnice vrijednosti za hotele u unaprjeđenju zadovoljstva gostiju.

POPIS LITERATURE

1. Boshof, C., & Elliot, R. (1 2005). The influence of organisational factors in small tourism businesses on the success of Internet marketing. *Management Dynamics : Journal of the Southern African Institute for Management Scientists, 14*(3), str. 44-58.
2. Tariq, M., Jamil, A., Ahmad, M. S., & Ramayah, T. (9 2019). Modeling the effectiveness of electronic customer relationship management (E-CRM) systems: empirical evidence from Pakistan. *Journal of Management & Technology, 19*(EE), str. 77-100.
3. Al-Shammari, M., & Mallouh, M. (2012). *Customer-Centric Knowledge Management: Concepts and Applications.* Hershey: IGI Global.
4. Alshourah, S., Alassaf, H., & Altawalbeh, M. (2018). Roles of Top Management and Customer Orientation in Enhancing the Performance of Customer Relationship Management (CRM) in Hotel Industry. *International Journal of Advance Research and Innovation, 6*(3), str. 233-239.
5. Anne Coussement, M., & Teague, T. J. (2013). The new customer-facing technology: Mobile and the constantly-connected consumer. *Journal of Hospitality and Tourism Technology, 42*(2), str. 177-187.
6. Appiah , B., & Kingsley, A. (2010). Towards a successful Customer relationship Management: A conceptual framework. *African Journal of Marketing Management, 2*(3), str. 37-43.
7. Baković, T., & Dužević, I. (2014). *Integrirani sustavi upravljanja.* Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu.
8. Banga, G., Kumar, B., & Goyal, H. (2013). Customer Relationship Management in Hotel Industry. *Pacific Business Review International, 5*(12), str. 71-81.
9. Baračkai, Z. (1987). *Odlučivanje o poslovnim strategijama.* Sarajevo: Svjetlost, Sarajevo, ekonomski institut, Sarajevo.
10. Belch, G. E., Belch, M., Kerr, G. F., & Powell, I. (2014). *Advertising: An integrated marketing communication perspective.* North Ryde, N.S.W.: McGraw-Hill Education.
11. Bilgihan, A., & Bujisic, M. (2015). The effect of website features in online relationship marketing: A case of online hotel booking. *Electronic Commerce Research and Applications, 14*(4), str. 222-232.
12. Bilgihan, A., Okumus, F., Nusair, K., & Kwun, D. (2011). Information technology applications and competitive advantage in hotel companies. *Journal of Hospitality and Tourism Technology, 2*(2), str. 139-154.
13. Blanchard, K., Ballard, J., & Finch, F. (2008). *Kupac na prvom mjestu.* Varaždin: Katraina Zrinski d.o.o.
14. Boban, M., & Babić, A. (2014). Utjecaj internetskih tehnologija na gospodarski rast, poslovni rezultat i stopu rasta profita poduzeća u Republici Hrvatskoj. *Zbornik radova Veleučilišta u Šibeniku, 1*(1-2), 59-82.

15. Bosilj Vukušić, V., & Pejić Bach, M. (2012). *Poslovna informatika.* Zagreb: Element.

16. Bowen, J., & Shoemaker, S. (1998). Loyalty: A strategic commitment. *Cornell Hotel and Restaurant Administration Quarterly, 39(1), 12–25.*, *39*(1), str. 12-25.

17. Buble, M. (2006). *Osnove menadžmenta.* Zagreb: Sonergija.

18. Buhalis, D., & Law, R. (2008). Progress in information technology and tourism management: 20 years on and 10 years after Internet-The state of e-Tourism research. *Tourism Management*,(29), str. 609 – 623.

19. Cantallops, A. S., & Salvi, F. (2014). New consumer behavior: A review of research on eWOM and hotels. *International Journal of Hospitality Management*(36), str. 41-51.

20. Cerović, Z. (2010). *Hotelski maenadžment* (2 izd.). Opatija: Sveučilište u Rijeci Fakultet za turistički i hotelski menadžment .

21. Cetinski, V. (2005). *Strateško upravljanje razvojem turizma i organizacijska dinamika.* Opatija: Fakultet za turistički i hotelski menadžment.

22. Čerović, S., & Knežević, M. (2019). *Menadžment u hotelijerstvu.* Beograd: Univerzitet Singidunum.

23. Ćirić, B. (2006). *Poslovna intekigencija.* Beograd: Data Status.

24. Davis, G. B., & Olson, M. H. (1985). *Management Information Systems: Conceptual Foundations, Structure and Development.* New York: McGrow-Hill.

25. Dewnarain, S., Ramkissoon, H., & Mavondo, F. (15. 10 2018). Social customer relationship management: An integrated conceptual framework. *Journal of Hospitality Marketing & Management*, str. 1-17.

26. Dewnarain, S., Ramkissoon, H., & Mavondo, F. (2019). Social customer relationship management in the hospitality industry. *Journal of Hospitality*, str. 1-14.

27. Di Gangi, P. M., & Wasko, M. M. (n.d.). Social media engagement theory: Exploring the influence of user engagement on social media usage. *Journal of Organizational and End User Computing*, *28*(2), str. 53–73.

28. Diffley, S., McCole, P., & Carvajal-Trujillo, E. (2018). Examining social customer relationship management among Irish hotels. *International Journal of Contemporary Hospitality Management*, *30*(2), str. 1072–1091.

29. Dominici, G., & Guzzo, R. (2010). Customer satisfaction in the hotel industry. A case study from Sicily. *International Journal of Marketing Studies*, *2*(2), str. 3-12.

30. Drucker, P. (1992). *Efikasan direktor.* Zagreb: Privredni vjesnik.

31. Dursun, A., & Caber, M. (2016). Using data mining techniques for profiling profitable hotel customers: An application of RFM analysis. *Tourism Management Perspectives*(18), str. 153-160.

32. Edinger, S. (20. 12 2018). *Why CRM Projects Fail and How to Make Them More Successful.* Dohvaćeno iz Harvard Business Review: https://hbr.org/2018/12/why-crm-projects-fail-and-how-to-make-them-more-successful

33. Eldridge, D. (12. 12 2018). *Why the 'R' in CRM Is the Most Important Letter in Customer Experience.* Dohvaćeno iz CMS Wire: https://www.cmswire.com/customer-experience/why-the-r-in-crm-is-the-most-important-letter-in-customer-experience/

34. Engelen, M., & Zafer, E. (5. 12 2019). Customer Relationship Management von Anfang an CRM und CRM Tools für junge Unternehmen. *Technology Arts Science* , str. 1-13. Preuzeto 25. 3 2020 iz https://epb.bibl.th-koeln.de/frontdoor/index/index/docId/1440

35. Fjermestad, J., & Robertson Jr, N. C. (2016). *Electronic Customer Relationship Management.* New York: Routledge .

36. Galičić, V., & Cerovac, Z. (2004). Menadžeri hotela i informacijska tehnologija. *Informatologia (1330-0067) 37 (2004), 3; 177-268, 37*(3), str. 177-268.

37. Galičić, V., & Šimunčić, M. (2006). *Informacijski sustavi i elektroničko poslovanje u turizmu.* Opatija: Fakultet za turistički i hotelski meenadžmant u Opatiji.

38. Garača, Ž., & Ćukušić, M. (2011). *Višedimenzijski informacijski sustavi.* Split: Ekonomski fakultetu Splitu.

39. Gartner. (10. 4 2018). *Gartner Says CRM Became the Largest Software Market in 2017 and Will Be the Fastest Growing Software Market in 2018.* Dohvaćeno iz Newsroom, Press Releases: https://www.gartner.com/en/newsroom/press-releases/2018-04-10-gartner-says-crm-became-the-largest-software-market-in-2017-and-will-be-the-fastest-growing-software-market-in-2018

40. Gilbert, D. C., Powell-Perry, J., & Widijoso, S. (1999). Approaches by hotels to the use of the Internet as a relationship marketing tool. *Journal of Marketing Practice: Applied Marketing Science, 5*(1), str. 21-38.

41. Grbin Praničević, D., Pivčević, S., & Garača, Ž. (2010). Razvijenost informacijskih sustava velikih hotelskih poduzeća u Hrvatskoj. *Acta Turistica Nova, 4*(2), str. 121-150.

42. Gretzel, U., Sigala, M., & Xiang, Z. (8 2015). Smart tourism: foundations and developments. *Electronic Markets, 25*(3), str. 179-188.

43. Griffin, R. W. (1990). *Management, treće izdanje.* Boston: Houhton Mifflin Co.

44. Groznik, A., & Kovačič, A. (2002). Does it have a real business value. *Management : Journal of Contemporary Management Issues, Vol. 7 No. 2, 2002., 7*(2), 20-30.

45. Hayes, D. K., & Ninemeier, J. D. (2005). *Upravljanje hotelskim poslovanjem.* Zagreb: M plus.

46. Haywood, K. M. (1988). Repeat patronage: Cultivating alliances with customers. *International Journal of Hospitality Management, 7*(3), str. 225–237.

47. Heizer, J., & Render, B. (1996). *Production and Operations Management.* New Jersey: Prentice Hall Internationa.

48. Homburg, C., Jozić, D., & Kuehnl, C. (2017). Customer experience management: Toward implementing an evolving marketing concept. *Journal of the Academy of Marketing Science, 45*(3), str. 377–401.

49. Horn , D., Feinberg, R., & Salvendy, G. (2005). Determinant elements of customer relationship management in e-business. *Behavior&Information Technology,, 24*(2), str. 101-109.

50. Hwang, J., Park, H. Y., & Hunter, W. C. (2015). Constructivism in smart tourism research: Seoul destination image. *Asia Pacific Journal of Information Systems, 25*(1), str. 163-178.

51. Kabiraj, S., & Shanmugan, J. (2009). ndigenous Customer Relationship Management Practices in Indian Automobile Companies: Strategic Implications. *International Journal of Management Perspectives, 4*(1), str. 1-25.

52. Kaplan, A., & Haenlein, M. (2012). Social media back to the roots and back to the future. *Journal of Systems and Information, 14*(2), str. 101-104.

53. Kast, F. E., & Rosenzwweigh, H. E. (1979). *Organization and management - a system approach.* McGraw Hili: New York.

54. Kim, M., Knutson, B. J., & Vogt, C. (2014). Post trip behavioral differences between first-time and repeat guests: a two-phase study in a hospitality setting. *Journal of Hospitality Marketing and Management, 23*(7), str. 722-745.

55. Klepić, Z. (25. 11 2019). *Donošenje odluka.* Dohvaćeno iz Donošenje odluka, Sistemi za potporu odlučivanju, nastavni materijali: http://ef.sum.ba/sites/default/files/nastavni-materijali/dono%C5%A1enje%20odluka.pdf

56. Kotler, P., Bowen, J., & Markens, J. (2010). *Marketing u ugostiteljstvu, hotelijerstvu i turizmu.* Zagreb: Data Status.

57. Kotler, P., & Keller, K. (2012). *A framework for marketing management.* Harlow: Pearson Education Limited.

58. Kreitner, R. (1993). *Management.* Boston: Haughton Mifflin Company.

59. Ku, E. C. (2010). The impact of customer relationship management through implementation of information systems. *Total Quality Management, 21*(11), str. 1085–1102.

60. Lang, T. (2000). The Effect of the Internet on travel consumer purchasing behaviour and implications for travel agencies. *Jounal of Vacation Marketing, 6*(4), str. 368-385.

61. Leung, X. Y., Bai, B., & Stahura, K. A. (2015). The marketing effectiveness of social media in the hotel industry: A comparison of Facebook and Twitter. *Journal of Hospitality & Tourism Research, 39*(2), str. 147-169.

62. Louvieris, P., Driver, J., & Powell-Perry, J. (2003). Managing customer behavior dynamics in the multi-channel e-business environment: Enhancing customer relationship capital in the global hotel industry. *Journal of Vacation Marketing, 9(2), 164–173, 9*(2), str. 164-173.

63. Lucey, T. (1995). *Management Information Systems* (8 izd.). London: DP Publications Ltd.

64. Luck, D., & Lancaster, G. (2003). e-CRM: Customer relationship management in the hotel industry. *Managerial Auditing Journal, 18*(3), str. 213-231.

65. Maggon, M., & Chaudhry, H. (2018). Exploring relationships between customer satisfaction and customer attitude from customer relationship management viewpoint: an empirical study of leisure travellers. *FIIB Business Review, 7*(1), str. 57-65.

66. Martinčić, A., Šmalcelj, M., & Ljubešić, J. (2010). Uspostava mehanizama nadzora i upravljanja integriranim informacijskim sustavom. *Hrvatski ogranak međunarodne elektrodistribucijske konferencije*, (str. 1-11). Umag.

67. Mateša, Z. (2019). *Uvod u strateški menadžment.* Zagreb: MATE d.o.o.

68. Mc Kim, B. (2002). The differences between Customer Relationship Management and database marketing. *Journal of Database Marketing*, str. 371-375.

69. Melville, N., Kreamer, K. L., & Gurbaxani, V. (2004). *Information Technology and Organizational Performance: An Integrative Model of IT Business Value.* Irvine: Center for Research on Information Technology and Organizations.

70. Meson, M., Alber, M., & Khedouri, E. (1985). *Management.* New York: Harper and Row.

71. Middletion, V., Fayll, A., Morgan, M., & Ranchhod, A. (2009). *Marketing in travel and tourism.* Oxford: Elsevier.

72. Muller, J. (2001). Upravljanje informacijskom tehnologijom u suvremenim tvrtkama te hrvatska poslovna praksa korištenja informacijskih tehnologija. *Ekonomski pregled, 52*(5-6), 587-612.

73. Muller, J., & Srića, V. (2005). *Hpravljanje odnosima s klijentima.* Zagreb: Delfin.

74. NN. (2018/42). *Zakona o provedbi Opće uredbe o zaštiti podataka .* Zagreb: Narodne novine d.o.o.

75. Noone, B. N., Kimes, S. E., & Renaghan, L. M. (2003). Integrating Customer Relationship Management and Revenue Management: A Hotel Perspective. *Cornell University School of Hotel Administration*, str. 1+31. Preuzeto 11. 11 2019 iz http://scholarship.sha.cornell.edu/articles

76. Nusair, K., & Kandampully, J. (18. 1 2008). The antecedents of customer satisfaction with online travel services: a conceptual model. *European Business Review*, str. 1-18.

77. O'Brien, J. A. (1999). *Introduction to Information Systems.* New York: McGraw-Hill, Inc.

78. O'Conor, P., & Murphy, J. (2004). A Review of Research on Information Technology in the Hospitality Industry. *International Journal of Hospitality Management, 23*(5), str. 473-484.

79. Olszak , C. M., & Ziemba, E. (2007). Approach to Building and Implementing Business Intelligence Systems. *Interdisciplinary Journal of Information, Knowledge, and Management, 2*(1), str. 135-148.

80. Ong, C. H., Lee, H. W., & Ramayah, T. (2018). Impact of brand experience on loyalty. *Journal of Hospitality Marketing & Management*, str. 1-20.

81. Otim, S., Dow, K. E., Grover, V., & Wong, J. A. (2012). The Impact of Information Technology Investments on Downside Risk of the Firm: Alternative Measurement of the Business Value of IT. *Journal of Management Information Systems, 29*(1), 159-193.

82. Panian, Ž. (2002). *Izazovi elektroničkog poslovanja.* Zagreb: Narodne novine d.d.

83. Panian, Ž., & Klepac, G. (2003). *Poslovna inteligencija.* Zagreb: Sinergija.

84. Parvatiyar , A., & Sheth, J. N. (2001). Customer relationship Management: Emerging Practice, Process and Discipline. *Journal of Economics & Sociological Research, 3*(2), str. 1-34.

85. Parvatiyar, A., & Sheth, J. N. (2001). Customer relationship management: Emerging practice, process, and discipline. *Journal of Economic & Social Research, 3*(2), str. 1-34.

86. Pavia , N. (2004). Hotelski menadžment koa poslovna funkcija. *Tourism and Hospitality Management, 10*(3-4), str. 127-132.

87. Payne, A., & Flow, P. (2013). *Strategic customer management: integrating relationship marketing and CRM.* Cambridge: Cambridge University Press.

88. Pfeifer, S. (2006). *Menadžment.* Osijek: Sveučilište J.J. Strossmayer, Ekonomski fakultet u Osijeku.

89. Piccoli, G. (2008). A framework for evaluating the business value of customer data in hospitality. *Journal of Hospitality and Leisure Marketing, 17*(1-2), str. 4-29.

90. Plazibat, I., Šušak, T., & Šarić, T. (2016). Funkcionalnost programa lojalnosti kupaca u maloprodaji. *Ekonomska misao i praksa, 25*(1), str. 303-318.

91. Porter, M. (1985). *Competitive Advantage (Creating and sustaining superior performance).* New York: The free Press.

92. Poslovni Dnevnik. (2018). *Globalni kibernetički napad – 50 milijardi dolara štete*. Preuzeto 22. 5 2019 iz http://www.poslovni.hr/tehnologija/globalni-kiberneticki-napad-50-milijardi-dolara-stete-339321

93. Radišić, F. (1997). *Poduzetnički menedžment u turizmu.* Opatija: Hotelijerski fakultet Opatija.

94. Rahimi, R., & Kozak, M. (2017). Impact of customer relationship management on customer satisfaction: The case of a budget hotel chain. *Journal of Travel and Tourism Marketing, 34*(1), str. 40-51.

95. Ray, S., Kim, S. S., & Morris, J. G. (2014). The central role of engagement in online communities. *Information Systems Research, 25*(3), str. 528-546.

96. Reinartz, W. J., & Kumar, V. (2002). The mismanagement of customer loyalty. *Harvard Business Review, 80*(7), str. 4-12.

97. Ryals, L., & Payne, A. (2001). Customer relationship management in financial services: towards information enabled relationship marketing,. *Journal of Strategic Marketing*, str. 3-27.

98. Sashi, C. M. (2012). Customer engagement, buyer-seller relationships, and social media. *Management Decision, 50*(2), str. 253-272.

99. Schroeder, R. G. (1989). *Operations Management, Decision Making in the Operations Function.* New York: McGraw-Hill Book Company.

100. Schwab, K. (2018). *The Fourth Industrial Revolution.* London: Penguin Books Publishers.

101. Senn, J. (1990). *Information Systems in Management, ., SAD, 1990., str. 501.* Belmont: Wadsforth Publishing Co.

102. Shanshan, N., Wilco, C., & Eric, S. (2011). A study of hotel frequent-guest programs: Benefits and costs. *Journal of Vacation Marketing, 17*(4), str. 315–327.

103. Sol, H. (1987). Paradoxes Around DSS. U C. W. Holaspple, & A. B. Whinston, *Decision Support Systems: Theory and Application* (str. 3-18). Berlin.

104. Sota , S., Chaudhry , H., & Srivastava, M. K. (8. 4 2019). Customer relationship management research in hospitality industry: a review and classification. *Journal of Hospitality Marketing & Management*, str. 1-26.

105. Sprague, R. H., & Carlson, E. D. (1982). *Building Effective Decision Support Systems.* New Jersey: Prentice-Hall.

106. Spremić, M. (2007). Metode provedbe revizije informacijskih sustava. *Zbornik Ekonomskog fakulteta u Zagrebu, 5*(1), str. 302-321.

107. Srića, V. (8 1933). Informatika i menadžment. *Računovodstvo, revizija i financije* , str. 45-59.

108. Stojanović, D. (1990). *Ekonomsko matematički metodi i modeli, Matrica rasta: dodatak,* . Beograd: Ekonomski fakultet.

109. Su, N., Mariadoss, B. J., & Reynolds, D. (2015). Friendship on social networking sites: Improving relationships between hotel brands and consumers. *International Journal of Hospitality Management*(51), str. 76-86.

110. Talón-Ballestero, P., González-Serrano, L., Muñoz-Romero, S., & Rojo-Alvarez, J. L. (2018). Using big data from Customer Relationship Management information systems to determine the client profile in the hotel sector. *Tourism Management*(68), str. 187-197.

111. Thao, H., & Swierczek, F. (2008). Internet use, customer relationships and loyalty in the Vietnamese travel industry. *Asia Pacific Journal of Marketing and Logistics, 20*(2), str. 190-210.

112. Thierauf, R. J. (1988). *User-Oriented Decision Support Systems.* New Jersay: Prentice Hall.

113. Timm, P. (2011). *Customer service-career success through customer loyalty.* New Jersey: Prentice Hall.

114. Turban , E., & Meredhith, J. R. (1991). *Fundamentals of Management Science.* Homewood: Irwin.

115. Turban, E. (1996). Implementing decision support systems: a survey. *IEEE International Conference on Systems, Man and Cybernetics. Information Intelligence and Systems (Cat. No.96CH35929)* (str. 50-62). Peking: IEEE.

116. Turban, E., & Aronson, J. E. (2006). *Decision Support Systems and Intelligent Systems.* New Jersey: Prentice Hall.

117. Varga , M., & Strugar, I. (2016). *Informacijski sustavi u poslovanju.* Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu.

118. Venkatesan, R. (2017). Executing on a customer engagement strategy. *Journal of the Academy of Marketing Science, 45*(3), str. 289-293.

119. Woodcock, N., Green, A., & Starkey, M. (2011). Social CRM as a business strategy. *Journal of Database Marketing & Customer Strategy Management*, str. 18-50.

120. Wynne, C., Berthon, P., Pitt, L., Ewing, M., & Napoli, J. (2001). The impact of the internet on the distribution value chain. *International Marketing Review, 18*(4), str. 420-431.

121. Xu, Y., Yen, D. C., Lin, B., & Chot , D. C. (2002). Adopting Customer Relationship Management technology. *Industrial Management & Data System, 108*(8), str. 442-452.

122. Yoo, W., Lee, Y., & Park, J. (2010). The role of interactivity in e-tailing: Creating value and increasing satisfaction. *Journal of Retailing and Consumer Services 17*, str. 89-96.

123. Zelenika, R., & Pupavac, D. (2008). *Menadžment logističkih sustava.* Rijela: Ekonomski fakultet Sveučilišta u Rijeci.

124. Zerbino, P., Aloini, D., Dulmin, R., & Mininno, V. (9 2018). Big Data-enabled Customer Relationship Management: A holistic approach. *Information Processing and Management, 54*(5), str. 818-846.

125. Znanje, H. j. (11. 11 2019). *Zadovoljan*. Dohvaćeno iz Hrvatski jezični portal - Znanje: http://hjp.znanje.hr/index.php?show=search_by_id&id=f15nWRF7

POPIS ILUSTRACIJA

POPIS SLIKA

Slika 1. Kontekst funkcioniranja odjela informatike i model upravljanja informacijskim sustavom poduzeća. 16
Slika 2. Dijelovi informacijskog sustava 18
Slika 3. Struktura integriranog informacijskog sustava 19
Slika 4. Strateški potencijal primjene IT-a u poslovanju 24
Slika 5. Uloge menadžera po Mintzbergu 35
Slika 6. Glavni koraci procesa strateškog menadžmenta 40
Slika 7. Dizajniranje strategije i strateško upravljanje 43
Slika 8. Modeli strateškog menadžmenta 44
Slika 9. Financijski i strateški ciljevi hotelskog poduzeća 45
Slika 10. Opći uvjeti za primjenu Porterovih generičkih strategija 46
Slika 11. Obilježja generičkih strategija 47
Slika 12. Procesuiranje informacija 52
Slika 13. Struktura generičkoga sustava za potporu odlučivanju 53
Slika 14. Usporedba između MIS-a i DSS-a 54
Slika 15. Generička struktura sustava za potporu odlučivanja u skupini 58
Slika 16. Podsustavi sustava za podršku odlučivanja 60
Slika 17. Proces rješavanja problema – sustav za podršku odlučivanja 61
Slika 18. Zadatci MIS-a 63
Slika 19. Sastavnice poslovnog informacijskog sustava 69
Slika 20. Odnos između sustava potpore, menadžerskih razina i tipova odluka 71
Slika 21. Integralni hotelski informacijski sustav 74
Slika 22. Sustav poslovne inteligencije 76
Slika 23. Infrastruktura poslovne inteligencije 77
Slika 24. Razlike između elektroničkog i pametnog turizma 80
Slika 25. Teorijski okvir perspektive CRM-a 81
Slika 26. Razvoj i upravljanje CRM-om 91
Slika 27. Potencijalni učinak *big d*ata na CRM 96
Slika 28. Komponente CRM-a 98
Slika 29. Životni ciklus CRM-a 102
Slika 30. Matrica lojalnosti 110
Slika 31. Segmentiranje gostiju prema lojalnosti hotelskom brendu 111
Slika 32. Predloženi okvir SCRM-a 118

POPIS GRAFIKONA

Grafikon 1. Frekvencija uzorka prema poslovnoj funkciji u % 122
Grafikon 2. Frekvencija uzorka prema dobi ispitanika u %..... 123
Grafikon 3. Frekvencija uzorka prema stupnju obrazovanja ispitanika u %..... 124
Grafikon 4. Frekvencija uzorka prema radnom iskustvu ispitanika u % 125
Grafikon 5. Frekvencija uzorka hotela prema lokaciji u %..... 126
Grafikon 6. Frekvencija uzorka hotela prema veličini u %..... 127
Grafikon 7. Frekvencija uzorka hotela prema vrsti poslovanja u % 128
Grafikon 8. Frekvencija uzorka hotela prema namjeni poslovanja u % 129
Grafikon 9. Grafička analiza distribucije ocjena konferencijskih usluga prema poziciji ispitanika i lokaciji hotela 180
Grafikon 10. Grafička analiza elemenata internog oglašavanja (I)..... 191
Grafikon 11. Grafička analiza elemenata internog oglašavanja (II) 192
Grafikon 12. Grafička analiza elemenata ostalih usluga prema stažu ispitanika i vrsti hotela 203
Grafikon 13. Distribucija ocjena funkcije – unaprjeđenje usmjerenosti gostiju prema potrošnji prema a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela 209
Grafikon 14. Distribucija ocjena funkcije – unaprjeđenje kvalitete usluge prema a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela..... 212
Grafikon 15. Distribucija ocjena funkcije – unaprjeđenje lojalnosti gostiju prema a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela..... 214
Grafikon 16. Distribucija ocjena funkcije – unaprjeđenje konkurentnosti hotela prema a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela 216
Grafikon 17. Distribucija ocjena funkcije – upravljanje podatkovnom bazom gostiju prema a) poziciji i b) dobi ispitanika te c) lokaciji i d) veličini hotela 218
Grafikon 18. Direktne stope razvoja elemenata CRM-a hotelske industrije..... 243
Grafikon 21. Indirektne stope rasta razvoje ljudskih potencijala u odnosu na druge razvojne elemente..... 244
Grafikon 20. Zadovoljstvo postojećim sustavom ICT-a u hotelu 245
Grafikon 21. Percepcija značaja informatičkog CRM-a u hotelu 246
Grafikon 22. Budućnost CRM-a u hotelijerstvu 247
Grafikon 25. Stavovi ispitanika o razvoju CRM-a..... 248

POPIS TABLICA

Tablica 1. Frekvencija i distribucija ocjena elementa telefonije i telefonskih aplikacija..... 131
Tablica 2. Bootstrap analiza ocjena elementa telefonije i telefonskih aplikacija..... 132
Tablica 3. Statistička analiza ocjena elementa telefonije i telefonskih aplikacija prema poziciji ispitanika 133
Tablica 4. Statistička analiza ocjena elementa telefonije i telefonskih aplikacija prema lokaciji hotela ispitanika 134
Tablica 5. Frekvencija i distribucija ocjena elementa integracije fiksne i mobilne telefonije na razini hotela..... 135
Tablica 6. Bootstrap analiza ocjena elementa integracije fiksne i mobilne telefonije na razini hotela..... 136
Tablica 7. Statistička analiza ocjena elementa integracije fiksne i mobilne telefonije na razini hotela prema poziciji ispitanika 137
Tablica 8 Statistička analiza ocjena elementa integracije fiksne i mobilne telefonije na razini hotela prema lokaciji hotela ispitanika 138
Tablica 9. Frekvencija i distribucija ocjena elementa hotelskog sustava reklamiranja 139
Tablica 10. Bootstrap analiza ocjena elementa hotelskog sustava reklamiranja..... 139
Tablica 11. Statistička analiza ocjena elementa hotelskog sustava reklamiranja prema poziciji ispitanika 140
Tablica 12 Statistička analiza ocjena elementa hotelskog sustava reklamiranja prema lokaciji hotela ispitanika..... 141
Tablica 13. Frekvencija i distribucija ocjena elementa zabave za goste kada su u sobama.. 142
Tablica 14. Bootstrap analiza ocjena elementa zabave za goste kada su u sobama..... 143
Tablica 15. Statistička analiza ocjena elementa zabave za goste kada su u sobama prema poziciji ispitanika 144
Tablica 16. Statistička analiza ocjena elementa zabave za goste kada su u sobama prema lokaciji hotela ispitanika..... 145
Tablica 17. Frekvencija i distribucija ocjena elementa dostupnosti interneta..... 146
Tablica 18. Bootstrap analiza ocjena elementa dostupnosti interneta..... 147
Tablica 19. Statistička analiza ocjena elementa dostupnosti interneta prema poziciji ispitanika 147
Tablica 20. Statistička analiza ocjena elementa dostupnosti interneta prema lokaciji hotela ispitanika..... 148
Tablica 21. Frekvencija i distribucija ocjena elementa kontrole ulaza 149
Tablica 22. Bootstrap analiza ocjena elementa kontrole ulaza 150
Tablica 23. Statistička analiza ocjena elementa kontrole ulaza prema poziciji ispitanika..... 151
Tablica 24. Statistička analiza ocjena elementa kontrole ulaza prema lokaciji hotela ispitanika 152
Tablica 25. Frekvencija i distribucija ocjena elementa kontrole i upravljanja minibarom 153
Tablica 26. Bootstrap analiza ocjena elementa kontrole i upravljanja minibarom 154
Tablica 27. Statistička analiza ocjena elementa kontrole i upravljanja minibarom prema poziciji ispitanika 155

Tablica 28. Statistička analiza ocjena elementa kontrole i upravljanja minibarom prema lokaciji hotela ispitanika 156
Tablica 29. Frekvencija i distribucija ocjena elementa upravljanja osvjetljenjem 157
Tablica 30. Bootstrap analiza ocjena elementa upravljanja osvjetljenjem 158
Tablica 31. Statistička analiza ocjena elementa upravljanja osvjetljenjem prema poziciji ispitanika 158
Tablica 32. Statistička analiza ocjena elementa upravljanja osvjetljenjem prema lokaciji hotela ispitanika 159
Tablica 33. Frekvencija i distribucija ocjena elementa upravljanja energijom 160
Tablica 34. Bootstrap analiza ocjena elementa upravljanja energijom 161
Tablica 35. Statistička analiza ocjena elementa upravljanja energijom prema poziciji ispitanika 162
Tablica 36. Statistička analiza ocjena elementa upravljanja energijom prema lokaciji hotela ispitanika 163
Tablica 37. Frekvencija i distribucija ocjena elementa upravljanja sigurnošću 164
Tablica 38. Bootstrap analiza ocjena elementa upravljanja sigurnošću 164
Tablica 39. Statistička analiza ocjena elementa upravljanja sigurnošću prema poziciji ispitanika 165
Tablica 40. Statistička analiza ocjena elementa upravljanja sigurnošću prema lokaciji hotela ispitanika 166
Tablica 41. Frekvencija i distribucija ocjena elementa pametnih kartica 167
Tablica 42. Bootstrap analiza ocjena elementa pametnih kartica 168
Tablica 43. Statistička analiza ocjena elementa integriranosti pametnih kartica prema poziciji ispitanika 169
Tablica 44. Statistička analiza ocjena elementa integriranosti pametnih kartica prema lokaciji hotela ispitanika 170
Tablica 45. Prosječne ocjene osnovnih usluga prema dobi ispitanika 171
Tablica 46. Analiza varijance osnovnih usluga prema starosnoj dobi ispitanika 172
Tablica 47. Prosječne ocjene osnovnih usluga prema namjeni hotela 173
Tablica 48. Analiza varijance osnovnih usluga prema namjeni hotela 174
Tablica 49. Korelacija elemenata osnovnih usluga 175
Tablica 50. Frekvencija i distribucija ocjena elementa IP telefonije 176
Tablica 51. Bootstrap analiza ocjena elementa IP telefonije 177
Tablica 52. Frekvencija i distribucija ocjena elementa videokonferencija 178
Tablica 53. Bootstrap analiza ocjena elementa videokonferencija 179
Tablica 54. χ^2 test značajnosti ocjena konferencijskih usluga prema poziciji ispitanika 181
Tablica 55. χ^2 test značajnosti ocjena konferencijskih usluga prema lokaciji hotela 181
Tablica 56. Analiza varijanci ocjena konferencijskih usluga prema dobi ispitanika 182
Tablica 57. Frekvencija i distribucija ocjena elementa plazma ekrana 183
Tablica 58. Bootstrap analiza ocjena elementa plazma ekrana 184
Tablica 59. Frekvencija i distribucija ocjena elementa infokioska 185
Tablica 60. Bootstrap analiza ocjena elementa infokioska 185
Tablica 61. Frekvencija i distribucija ocjena elementa ekrana na VoIP telefonima u sobi 186
Tablica 62. Bootstrap analiza ocjena elementa ekrana na VoIP telefonima u sobi 187

Tablica 63. Frekvencija i distribucija ocjena elementa IP televizija u sobama 188
Tablica 64. Bootstrap analiza ocjena elementa IP televizija u sobama 188
Tablica 65. Frekvencija i distribucija ocjena elementa internih mrežnih stranice i mrežnih portala za goste 189
Tablica 66. Bootstrap analiza ocjena elementa internih mrežnih stranica i mržnih portala za goste 190
Tablica 67. χ^2 test značajnosti ocjena internog oglašavanja prema obrazovanju ispitanika . 193
Tablica 68. χ^2 test značajnosti ocjena konferencijskih usluga prema veličini hotela 194
Tablica 69. Analiza varijanci ocjena usluga internog oglašavanja prema dobi ispitanika 195
Tablica 70. Korelacija prosječnih ocjena elemenata usluge internog oglašavanja 196
Tablica 71. Frekvencija i distribucija ocjena elementa interaktivnih informacija o događanjima u destinaciji 197
Tablica 72. Bootstrap analiza ocjena elementa interaktivnih informacija o događanjima u destinaciji 198
Tablica 73. Frekvencija i distribucija ocjena elementa interaktivne rezervacije restorana 199
Tablica 74. Bootstrap analiza ocjena elementa interaktivne rezervacije restorana 200
Tablica 75. Frekvencija i distribucija ocjena elementa interaktivne rezervacije rekreativnih sadržaja 201
Tablica 76. Bootstrap analiza ocjena elementa interaktivne rezervacije rekreativnih sadržaja 202
Tablica 77. χ^2 test značajnosti ocjena internog oglašavanja prema obrazovanju ispitanika . 204
Tablica 78. χ^2 test značajnosti ocjena konferencijskih usluga prema veličini hotela 205
Tablica 79. Analiza varijanci ocjena ostalih usluga prema lokaciji ispitanikova hotela 206
Tablica 80. Korelacija prosječnih ocjena elemenata ostalih usluga 207
Tablica 81. Frekvencija i distribucija ocjena funkcije CRM-a unaprjeđenje usmjerenosti gostiju prema potrošnji 208
Tablica 82. Frekvencija i distribucija ocjena funkcije CRM-a unaprjeđenje kvalitete usluge 211
Tablica 83. Frekvencija i distribucija ocjena funkcije CRM-a unaprjeđenje lojalnosti gostiju 213
Tablica 84. Frekvencija i distribucija ocjena funkcije CRM-a unaprjeđenje konkurentnosti hotela 215
Tablica 85. Frekvencija i distribucija ocjena funkcije CRM-a upravljanje podatkovnom bazom gostiju 217
Tablica 86. Analiza varijanci ocjena funkcija CRM-a prema stupnju obrazovanja ispitanika 219
Tablica 87. Analiza varijanci ocjena funkcija CRM-a prema vrsti hotela 220
Tablica 88. Korelacija prosječnih ocjena funkcija CRM-a 221
Tablica 89. Frekvencija i distribucija ocjena funkcije CRM-a pravljanje prodajnim procesom 223
Tablica 90. Ocjene korisničke funkcije upravljanja prodajnim procesom prema profilu ispitanika i objekta 224
Tablica 91. Frekvencija i distribucija ocjena funkcije CRM-a jedinstvena lista gostiju, dobavljača i partnera 225

Tablica 92. Ocjene korisničke funkcije jedinstvene liste gostiju, dobavljača i partnera prema profilu ispitanika i objekta 226
Tablica 93. Frekvencija i distribucija ocjena funkcije CRM-a jedinstvena lista afiniteta gostiju 227
Tablica 94. Ocjene korisničke funkcije jedinstvene liste afiniteta gostiju prema profilu ispitanika i objekta 228
Tablica 95. Frekvencija i distribucija ocjena funkcije CRM-a upravljanje reklamacijama ... 229
Tablica 96. Ocjene korisničke funkcije upravljanja reklamacijama prema profilu ispitanika i objekta 230
Tablica 97. Frekvencija i distribucija ocjena funkcije CRM-a praćenje konkurencije 231
Tablica 98. Ocjene korisničke funkcije praćenja konkurencije prema profilu ispitanika i objekta 232
Tablica 99. Frekvencija i distribucija ocjena funkcije CRM-a integracija s elektroničkom poštom i potpora za *mail merge* 233
Tablica 100. Ocjene korisničke funkcije integracije s elektroničkom poštom i potpora za *mail merge* 234
Tablica 101. Analiza varijanci ocjena korisničkih funkcija CRM-a prema poziciji ispitanika 235
Tablica 102. Analiza varijanci ocjena korisničkih funkcija CRM-a prema lokaciji hotela ... 236
Tablica 103. Korelacija funkcija korisničke podrške 237
Tablica 104. Vrednovanje elemenata razvoja CRM-a 240
Tablica 105. Matrica razvoja CRM-a u hotelskoj industriji 242
Tablica 106. Stope rasta razvojnih elemenata CRM-a u hotelskoj industriji 242

PRILOG – ANKETNI UPITNIK

Anketni upitnik

1. ***Osnovni podatci o ispitaniku.*** Potrebno je u priloženoj tablici s ***X*** označiti Vašu poziciju u hotelu, dob, stupanj obrazovanja i radno iskustvo.

Pozicija	
Direktor hotela	
Direktor marketinga	
Šef recepcije	
Dob	
do 35 godina	
od 36 do 45 godina	
od 46 do 55 godina	
Više od 56 godina	
Stupanj obrazovanja	
srednji	
viši	
visoki	
magisterij doktorat	
Radno iskustvo	
do 5 godina	
od 6 do 10 godina	
od 11 do 20 godina	
od 21 do 30 godina	
više od 30 godina	

2. ***Osnovni podatci o objektu istraživanja.*** Potrebno je u priloženoj tablici s ***X*** označiti lokaciju, veličinu, vrstu i namjenu hotela u kojem Vi kao ispitanik djelujete.

Lokacija hotela	
Priobalje	
Otoci	
Kontinent	
Urbana	
Veličina hotela	
Do 100 soba	
101 -200 soba	
Više od 200 soba	
Vrsta hotela	
Hotel s cjelogodišnjim poslovanjem	
Hotel sa sezonskim poslovanjem	
Hotel specijaliziran za kongresni turizam	
Aparthotel	
Hotel s cjelogodišnjim poslovanjem	
Namjena hotela	
Odmor	
Sport i zabava	

Zdravlje i wellness	
Kongres i posao	
Urbana	

3. **Ocjena elemenata postojećeg stanja** sustava integriranih komunikacijskih usluga u vašem hotelu. Potrebno je ocjenom od 1 do 10 ocijeniti pojedine elemente postojećeg sustava. Važno je iznijeti subjektivne stavove proizašle iz osobnog iskustva te komunikacije s gostima i poslovnim partnerima.

ELEMENTI INTEGRIRANIH KOMUNIKACIJSKIH USLUGA U HOTELU		**OCJENA**
Osnovne usluge		
1.	Telefonija i telefonske aplikacije	
2.	Integracija fiksne i mobilne telefonije na razini hotela	
3.	Hotelski sustav reklamiranja	
4.	Zabavu za goste kad su u sobama (entertainment TV, video sadržaj na zahtjev, igranje, kockanje ili druge igre na sreću, glazba po ukusu gosta i drugi sadržaji)	
5.	Dostup Internetu (žicom ili bežično)	
6.	Kontrola ulaza	
7.	Kontrola i upravljanje mini-barom	
8.	Osvjetljenje (Lighting)	
9.	Upravljanje energijom, grijanje, ventilacija, klima uređaji	
10.	Sigurnost – vatrodojava i poziv za pomoć, video nadzor	
11.	Integraciju i korištenje pametnih kartica (Smart Card billing)	
Konferencijske usluge		
1.	IP telefonija	
2.	Videokonferencijske usluge, kao i prijenos Video signala putem IP-a	
Interno oglašavanje		
1.	Plazma ekrani u predvorju, na recepciji, baru, restoranu…	
2.	Umreženi info-kiosci postavljeni na ključnim i prometnim mjestima u hotelu	
3.	Ekrani na IP telefonima u svakoj hotelskoj sobi	
4.	IP televizija u svakoj sobi	
5.	Interne web stranice hotela i web-portal za goste	
Ostale usluge		
1.	Interaktivne informacije o događajima u destinaciji	
2.	Interaktivna rezervacija restorana	
3.	Interaktivna rezervacija rekreativnih sadržaja	

4. **Ocjena funkcija CRM sustava.** Potrebno je ocjenom od 1 do 10 ocijeniti pojedine funkcije CRM-a. Važno je iznijeti subjektivne stavove proizašle iz osobnog iskustva te komunikacije s relevantnim subjektima – korisnicima CRM-a.

FUNKCIJE CRM-a		**OCJENA**
1.	Unaprjeđenje usmjerenosti gostiju potrošnji	
2.	Unaprjeđenje kvalitete pružene usluge	
3.	Unaprjeđenje lojalnosti gostiju	
4.	Unaprjeđenje konkurentnosti hotela	

5.	Upravljanje bazom gostiju i neposredno dobivanje povratnih informacija	

5. **Ocjena korisničke podrške CRM sustava**. Potrebno je ocjenom od 1 do 10 ocijeniti pojedine funkcije CRM-a. Važno je iznijeti subjektivne stavove proizašle iz osobnog iskustva te komunikacije s relevantnim subjektima – korisnicima CRM-a.

Korisnička podrška CRM-a		**OCJENA**
1.	Upravljanje prodajnim procesom (rezervacija, naplata, rezervacija)	
2.	Jednostavna lista svih gostiju, dobavljača i partnera	
3.	Jednostavna lista afiniteta gostiju (grupa, parova s djecom, pojedinaca)	
4.	Upravljanje reklamacijama	
5.	Praćenje konkurencije (cijene, usluge, događaji)	
6.	Integracija s elektronskom poštom i potpora za mail merge	

6. **Razvojni elementi.** Vrednujete s ocjenom od 1 do 10 razvojne elemente CRM-a onako kako ih Vi procjenjujete danas te kakvim ih, s obzirom na društvene, političke i gospodarske okolnosti te činjenicom da se Hrvatska nalazi u Europskoj uniji očekujete 2022. godine.

RAZVOJNI ELEMENTI CRM-a		**Godina**	
		2018.	**2022.**
1.	Ljudski potencijali - spremnost prihvaćanja i korištenja CRM-a		
2.	ICT infrastruktura		
3.	Pouzdanost tehnologije i kompatibilnost s drugim sustavima		
4.	Informacijske tehnologije u međuorganizacijskim sustavima		
5.	Zahtjevi za personaliziranije odnosa hotela s gostom		
6.	Zahtjevi za personaliziranije odnosa gosta s hotelom		
7.	Financijski potencijali		
8.	Bruto domaći proizvod		
9.	Razvoj tehnologije (inteligentni softveri, novi mobilni sustavi)		
10.	Sustav unaprjeđenja kvalitete usluga		
11.	Troškovi proizvodnje hotelijerske usluge		
12.	Hotelska etika i društvena odgovornost		
13.	Hotelski imidž		
14.	Hotelska kultura		

Slijedeća grupa pitanja traži konkretne odgovore o postojećoj integriranosti ICT usluga u Vašem hotelu te otvorenosti za implementaciju CRM sustava. Potrebno je izraziti Vaše subjektivne stavove proizašle iz osobnog iskustva te komunikacije s gostima, dobavljačima, turoperatorima, partnerima i lokalnom zajednicom na način da markirate (osjenčate) odgovor koji smatrate da je ispravan.

7. Da li postojeći sustav ICT-a zadovoljava Vaše potrebe odnosno očekivanja od suvremenog informatičkog sustava:

a) zadovoljava u cijelosti
b) djelomično zadovoljava
c) ne zadovoljava

8. Po vašem mišljenju informatički CRM sustav je:

a) ključna pretpostavka suvremenog odnosa hotela i gosta,
b) dobar način zadovoljenja potreba gostiju
c) samo alat koji pomaže poslovanju

9. U nekom budućem modelu učinkovitog kreiranja odnosa s gostima CRM sustav bi trebao biti:

a) dominantan alat upravljanja hotelskim sustavom,
b) važan dio marketinga u kombinaciji s klasičnim marketinškim alatima,
c) samo nužan alat za održavanje koraka s novim tehnologijama

10. Po Vašem mišljenju razvoj CRM- a treba:

a) postati sastavni dio integriranog informatičkog sustava hotela,
b) sustavno uvoditi CRM u skladu s trendovima prihvaćanja novih tehnologija,
c) prepustiti stvar trendovima u hotelijerstvu bez posebnog inzistiranja na CRM-u.