

Doprinos povećanju učinkovitosti održavanja kanalizacijskih sustava primjenom modela procjene troškova održavanja

Obradović, Dino

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Civil Engineering and Architecture Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:133:322250>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-04-25**



Repository / Repozitorij:

[Repository GrAFOS - Repository of Faculty of Civil Engineering and Architecture Osijek](#)



Sveučilište Josipa Jurja Strossmayera u Osijeku
Građevinski i arhitektonski fakultet Osijek

Poslijediplomski sveučilišni studij Građevinarstvo

Doktorska disertacija

Doprinos povećanju učinkovitosti održavanja kanalizacijskih
sustava primjenom modela procjene troškova održavanja

Dino Obradović, mag. ing. aedif.

Osijek, 31. ožujka 2022. godine

Josip Juraj Strossmayer University of Osijek
Faculty of Civil Engineering and Architecture Osijek

Postgraduate University Study Programme in Civil Engineering

Doctoral dissertation

A contribution to increasing the efficiency of sewerage
systems maintenance by applying a maintenance cost
estimation model

Dino Obradović, M.Sc. in Civ. Eng.

Osijek, March 31, 2022

Prosudbena povjerenstva i bibliografski podaci

Povjerenstvo za prihvaćanje teme doktorske disertacije

Povjerenstvo za prihvaćanje teme doktorske disertacije imenovano na 1. redovitoj sjednici Fakultetskog vijeća Građevinskog i arhitektonskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku, održanoj 14. listopada 2020. godine:

1. *Izv. prof. dr. sc. Hrvoje Krstić, dipl. ing. građ., Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek (predsjednik Povjerenstva)*
2. *Prof. dr. sc. Saša Marenjak, dipl. ing. građ., Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek (član)*
3. *Prof. dr. sc. Diana Car-Pušić, dipl. ing. građ., Sveučilište u Rijeci, Građevinski fakultet (članica)*

Tema, mentor i komentorica doktorske disertacije prihvaćeni su odlukom Fakultetskog vijeća Građevinskog i arhitektonskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku na 3. redovitoj sjednici održanoj 11. studenoga 2020. godine.

Povjerenstvo za ocjenu doktorske disertacije

Povjerenstvo za ocjenu doktorske disertacije imenovano na 4. redovitoj sjednici Fakultetskog vijeća Građevinskog i arhitektonskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku, održanoj 12. siječnja 2022. godine:

1. *Izv. prof. dr. sc. Hrvoje Krstić, dipl. ing. građ., Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek (predsjednik Povjerenstva)*
2. *Prof. dr. sc. Saša Marenjak, dipl. ing. građ., Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek (član i mentor)*
3. *Prof. dr. sc. Diana Car-Pušić, dipl. ing. građ., Sveučilište u Rijeci, Građevinski fakultet (članica)*

Doktorska disertacija prihvaćena je odlukom Fakultetskog vijeća Građevinskog i arhitektonskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku na 6. redovitoj sjednici održanoj 9. ožujka 2022. godine.

Povjerenstvo za obranu doktorske disertacije

Povjerenstvo za obranu doktorske disertacije imenovano na 6. redovitoj sjednici Fakultetskog vijeća Građevinskog i arhitektonskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku, održanoj 9. ožujka 2022. godine:

1. *Izv. prof. dr. sc. Hrvoje Krstić, dipl. ing. građ., Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek (predsjednik Povjerenstva)*
2. *Prof. dr. sc. Saša Marenjak, dipl. ing. građ., Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek (član i mentor)*
3. *Prof. dr. sc. Diana Car-Pušić, dipl. ing. građ., Sveučilište u Rijeci, Građevinski fakultet (članica)*
4. *Prof. dr. sc. Zlata Dolaček-Alduk, dipl. ing. građ., Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek (zamjenska članica)*

Doktorska disertacija javno je obranjena 31. ožujka 2022. godine na Građevinskom i arhitektonskom fakultetu Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku.

Doktorska disertacija sadržava *178 stranica, 34 ilustracije, 33 tablice, 5 dodataka i 332 citirane publikacije.*

Mentor doktorske disertacije je prof. dr. sc. Saša Marenjak, dipl. ing. građ., Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek.

Komentorica doktorske disertacije je izv. prof. dr. sc. Marija Šperac, dipl. ing. građ., Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek.

Istraživanje u okviru doktorske disertacije pripada znanstvenom području tehničkih znanosti, znanstvenom polju građevinarstvo.

Izjava o akademskoj čestitosti

Izjavljujem i svojim potpisom potvrđujem kako je doktorska disertacija isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija. Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, odnosno prepisan iz necitiranog rada te kako nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem kako nisam prijavio doktorsku disertaciju s istovjetnom temom na drugom studiju Sveučilišta ili na drugom sveučilištu.

Osijek, 31. ožujka 2022.

Dino Obradović, mag. ing. aedif.

Predgovor

Ova doktorska disertacija obrađuje problematiku održavanja kanalizacijskih sustava u Republici Hrvatskoj. Kako bi se omogućilo bolje održavanje kanalizacijskih sustava, u doktorskoj disertaciji predložen je model procjene troškova održavanja kanalizacijskih sustava te odgovarajuća struktura troškova održavanja kanalizacijskog sustava. Poduzećima koja upravljaju kanalizacijskim sustavima u Republici Hrvatskoj model procjene troškova održavanja trebao bi omogućiti procjenu budžeta za određeno razdoblje. Kao rezultat pregleda postojeće literature te provedenog istraživanja, dani su zaključci i smjernice za daljnja istraživanja koji se nalaze na kraju doktorske disertacije.

Zahvaljujem svom mentoru prof. dr. sc. Saši Marenjaku i komentorici izv. prof. dr. sc. Mariji Šperac na pomoći, usmjeravanju, svim dogovorima oko rada te uloženom vremenu i trudu. Također, hvala mojoj kolegici Mihaeli za svu pomoć i savjete oko izrade prezentacije za obranu doktorske disertacije.

Najveća hvala mojoj obitelji koja me je ohrabivala, podupirala, vjerovala u mene.

Hvala svim poduzećima koja su sudjelovala u istraživanju. Hvala i svim mojim studentima bivšim i sadašnjim. Hvala svima od kojih sam učio.

Sažetak

U svrhu izrade ove doktorske disertacije provedeno je istraživanje o mogućnosti prikupljanja podataka i informacija o karakteristikama kanalizacijskih sustava u Republici Hrvatskoj te o troškovima njihovog održavanja. Podatci su prikupljeni pomoću upitnika poslanim poduzećima koja upravljaju kanalizacijskim sustavima. Kao rezultat prikupljenih podataka i informacija napravljena je baza podataka koja je služila za razvoj modela procjene troškova održavanja kanalizacijskih sustava. Analizom takve baze podataka te pregledom literature omogućeno je identificiranje varijabli koje su značajne u procjeni troškova održavanja te, na kraju, izrada samog modela za procjenu troškova održavanja kanalizacijskog sustava. Također, razvijena je struktura podataka i troškova održavanja kanalizacijskog sustava koja omogućuje lakše praćenje troškova na godišnjoj razini. Takvim pristupom osigurava se međusobna usporedivost troškova o održavanju kanalizacijskih sustava u Republici Hrvatskoj. Utvrđena je mogućnost primjene linearne regresije kod izrade modela procjene troškova održavanja kanalizacijskog sustava. Budući da je definiran model procjene troškova održavanja kanalizacijskog sustava, utvrđene su i varijable koje najviše utječu na te troškove. Definirane su prednosti i ograničenja modela procjene troškova održavanja. Najveća prednost modela procjene troškova održavanja je jednostavnost uporabe te potreban mali broj podataka o kanalizacijskom sustavu koji su dostupni već u fazi projektiranja. Primjenom modela procjene troškova održavanja moguće je planirati proračun za održavanje kanalizacijskih sustava na razini određenog poduzeća u Republici Hrvatskoj za određena razdoblja. Korištenjem ovog modela očekuje se poboljšanje učinkovitosti održavanja kanalizacijskih sustava i uporaba metode troškova životnog ciklusa budući da će se već pri projektiranju moći procijeniti troškovi održavanja kanalizacijskih sustava.

Ključne riječi

kanalizacijski sustavi, model procjene troškova, održavanje, povećanje učinkovitosti održavanja, struktura troškova održavanja

Autor: Dino Obradović, mag. ing. aedif.

Mentor: prof. dr. sc. Saša Marenjak, dipl. ing. građ.

Komentorica: izv. prof. dr. sc. Marija Šperac, dipl. ing. građ.

Abstract

For the purpose of preparation of this doctoral dissertation, a survey was conducted on the feasibility of collecting data and information on the properties of sewerage systems in the Republic of Croatia and on the costs of sewerage systems maintenance. The data were collected through questionnaires sent to companies managing sewerage systems. As a result of collected data and information on the properties and costs of sewerage systems' maintenance, a database was created. The database was used to develop a maintenance cost estimation model for sewerage systems. The analysis of such a database and literature review has enabled the identification of variables that are significant in estimating maintenance costs and developing the maintenance cost estimation model of the sewerage system. Also, data structure and maintenance costs structure of sewerage system have been developed enabling easier monitoring of annual costs. This approach ensures mutual comparability of maintenance costs on sewerage systems in the Republic of Croatia. The possibility of applying linear regression in developing the maintenance cost estimation model of sewerage system has been established. A maintenance cost estimation model of sewerage system has been defined. In addition to this, the variables that most affect the maintenance cost of sewerage system have been identified. Advantages and limitations of the maintenance cost estimation model have been defined. The greatest advantage of the maintenance cost estimation model is the simplicity of use with a small amount of the required sewerage system data, which are already available at the beginning of the design elaboration process. By applying the maintenance cost estimation model, it is possible to plan a budget for the maintenance of sewerage systems at the level of a particular company in the Republic of Croatia and for specific time period. The use of this model is expected to improve the efficiency of sewerage system maintenance and use of the life cycle cost method, since it will be possible to estimate the maintenance costs of sewerage systems already during the design process.

Keywords

sewerage systems, cost estimation model, maintenance, increasing maintenance efficiency, maintenance cost structure

SADRŽAJ

POPIS SLIKA	XVII
POPIS TABLICA.....	XIX
POPIS KRATICA I SIMBOLA	XXI
1. UVOD.....	1
1.1. Predmet istraživanja	1
1.2. Ciljevi i hipoteze istraživanja.....	7
1.3. Metode i postavke istraživanja.....	9
1.4. Struktura disertacije.....	12
2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA O ODRŽAVANJU GRAĐEVINA I TROŠKOVIMA ODRŽAVANJA GRAĐEVINA.....	14
2.1. Gospodarenje građevinama	14
2.2. Životni ciklus i održavanje građevine	16
2.3. Dosadašnja istraživanja o mogućnostima optimizacije održavanja kanalizacijskog sustava	25
2.4. Dosadašnja istraživanja o predviđanju troškova održavanja građevina.....	32
3. KANALIZACIJSKI SUSTAVI	39
3.1. Povijest kanalizacijskih sustava	39
3.2. Kanalizacijski sustav i vrste kanalizacijskih sustava	41
3.3. Održavanje kanalizacijskih sustava.....	49
3.4. Stanje usluga odvodnje i kanalizacijskog sustava u državama u okruženju i Republici Hrvatskoj	64
4. PRIKUPLJANJE I OBRADA PODATAKA	68
4.1. Upitnik.....	68
4.2. Odaziv na upitnik i prikupljeni podatci.....	73
4.3. Analiza podataka i odgovora iz upitnika.....	78
4.4. Statistička obrada podataka	83
4.4.1. Osnovna statistička obrada podataka.....	83
4.4.2. Odabir statističke metode i varijabli modela	85
5. RAZVOJ MODELA I VALIDACIJA MODELA PROCJENE TROŠKOVA ODRŽAVANJA KANALIZACIJSKOG SUSTAVA	97
5.1. Razvoj modela procjene troškova održavanja kanalizacijskog sustava	97
5.1.1. Model I procjene troškova održavanja	105
5.1.2. Model II procjene troškova održavanja	105
5.1.3. Model III procjene troškova održavanja.....	106

5.1.4. Model IV procjene troškova održavanja	106
5.2. Validacija modela procjene troškova održavanja kanalizacijskog sustava.....	108
5.2.1. Metode validacije modela.....	109
5.2.2. Validacija modela I procjene troškova održavanja kanalizacijskog sustava.....	111
5.2.3. Validacija modela II procjene troškova održavanja kanalizacijskog sustava.....	111
5.2.4. Validacija modela III procjene troškova održavanja kanalizacijskog sustava	112
5.2.5. Validacija modela IV procjene troškova održavanja kanalizacijskog sustava	112
5.3. Analiza osjetljivosti modela procjene troškova održavanja kanalizacijskog sustava .	113
5.3.1. Analiza osjetljivosti modela I procjene troškova	115
5.3.2. Analiza osjetljivosti modela II procjene troškova	116
5.3.3. Analiza osjetljivosti modela III procjene troškova.....	117
5.4. Prednosti i ograničenja modela procjene troškova održavanja kanalizacijskog sustava	118
5.4.1. Prednosti modela procjene troškova održavanja	118
5.4.2. Ograničenja modela procjene troškova održavanja.....	119
5.5. Sažeti prikaz rezultata istraživanja.....	121
6. ZAKLJUČCI I SMJERNICE ZA DALJNJA ISTRAŽIVANJA	123
6.1. Zaključak.....	123
6.2. Smjernice za daljnja istraživanja.....	126
POPIS LITERATURE	129
PRILOG 1 – Zamolba za dostavu podataka i anketni upitnik za poduzeća koja upravljaju kanalizacijskim sustavima	149
PRILOG 2 – Deskriptivna statistika baze podataka za razvoj matematičkog modela procjene troškova održavanja	156
PRILOG 3 – Korelacije zavisne i neovisnih varijabli.....	158
PRILOG 4 – Dijagrami raspršenosti za model s interakcijama.....	170
PRILOG 5 – Prijedlog obrasca za ujednačeno prikupljanje podataka o održavanju kanalizacijskog sustava	174
CURRICULUM VITAE.....	177

POPIS SLIKA

Slika 2.1. Izazovi unutar aktivnosti gospodarenja građevinama [51]	16
Slika 2.2. Vrijednost informacije kao funkcija vremena (prilagođeno prema: [53]).....	17
Slika 2.3. Životni ciklus građevine [55].....	18
Slika 2.4. Propadanje i održavanje građevina kroz vrijeme [55]	19
Slika 2.5. Troškovi upravljanja, održavanja i uporabe građevine [27]	22
Slika 2.6. Mogućnost utjecaja na troškove projekta (prilagođeno prema: [102]).....	33
Slika 3.1. Mješoviti sustav odvodnje [151]	44
Slika 3.2. Razdjelni sustav odvodnje [151]	46
Slika 3.3. Polurazdjelni sustav odvodnje [151]	46
Slika 3.4. Kombinirani sustav odvodnje [151]	47
Slika 3.5. Mlaznice za čišćenje kanalizacije [202]	56
Slika 3.6. Kamion za čišćenje cijevi vodom pod pritiskom [203]	56
Slika 3.7. Prikaz postavljanja nove kanalizacijske cijevi i izrade kontrolnog okna	61
Slika 3.8. Priključenost na kanalizaciju, priključenost na UPOV i pristup zahodu na ispiranje za deset promatranih država.....	65
Slika 3.9. Duljina kanalizacijske mreže za deset promatranih država	66
Slika 4.1. Odaziv na zamolbu i upitnik.....	73
Slika 4.2. Udio poduzeća koja su dostavila ispunjene upitnike	74
Slika 4.3. Struktura valjanosti dostavljenih podataka	75
Slika 4.4. Struktura podataka prema broju godina za koji su dostavljeni podatci	75
Slika 4.5. Prikaz duljine kanal. sustava i broja zaposlenih na poslovima održavanja kanal. sustava.....	79
Slika 4.6. Prikaz duljine kanal. sustava i broj priključaka na kanal. sustav.....	79
Slika 4.7. Prikaz duljine kanal. sustava i prosječne godišnje količine odvođenja otpadnih voda	80
Slika 4.8. Prikaz odgovora na pitanje: „Temelji li se održavanje kanal. sustava samo na popravljanju kvarova i nedostataka?“	81
Slika 4.9. Prikaz odgovora na pitanje: „Postoji li preventivna strategija održavanja kanalizacijskog sustava za određeno razdoblje?“	82
Slika 4.10. Prikaz odgovora na pitanje: „Mislite li da je isplativije preventivno ili reaktivno održavanje...?“	82

Slika 4.11. Koraci izgradnje statističkog modela [261]	86
Slika 4.12. Korelacija slučajnih varijabli [256]	87
Slika 5.1. Vrijednosti koeficijenta determinacije i podešenog koeficijenta determinacije za promatrane modele.....	99
Slika 5.2. Vrijednosti srednje apsolutne pogreške za promatrane modele	102
Slika 5.3. Vrijednosti Akaikeovog informacijskog kriterija za promatrane modele	102
Slika 5.4. Rezultati analize osjetljivosti modela I.....	115
Slika 5.5. Rezultati analize osjetljivosti modela II	116
Slika 5.6. Rezultati analize osjetljivosti modela III za varijablu ukupna duljina kanal. sustava	117
Slika 5.7. Rezultati analize osjetljivosti modela III za varijablu broj crpnih stanica.....	118

POPIS TABLICA

Tablica 2.1. Sažeti kronološki prikaz istraživanja o modelima predviđanja i procjene troškova održavanja različitih vrsta građevina	37
Tablica 3.1. Primjeri različitih modela svrdala za stroj za čišćenje kanalizacije (izrada autora prema: [200])	55
Tablica 3.2. Metode pregleda i inspekcije kanalizacijskog sustava [209]	58
Tablica 3.3. Najčešća oštećenja kod kanalizacijskih cijevi [210], [211]	60
Tablica 3.4. Priključenost na kanalizaciju, priključenost na uređaj za pročišćavanje otpadnih voda i pristup zahodu na ispiranje za promatrane države (izrada autora prema: [226]–[238])	65
Tablica 3.5. Duljine kanalizacijske mreže i broj priključaka po km mreže za promatrane države (izrada autora prema: [226]–[238])	66
Tablica 3.6. Prikaz određenih pokazatelja kanalizacijskih sustava za Republiku Hrvatsku (izrada autora prema: [239], [240])	67
Tablica 4.1. Razvijena struktura podataka i troškova održavanja kanalizacijskog sustava	70
Tablica 4.2. Popis poduzeća kojima su poslani upitnici na području Republike Hrvatske	71
Tablica 4.3. Podatci o obuhvatu provedenog istraživanja	76
Tablica 4.4. Popis mogućih neovisnih varijabli modela procjena troškova održavanja kanalizacijskog sustava	77
Tablica 4.5. Ukupna sadašnja vrijednost troškova održavanja, prosječna godišnja sadašnja vrijednost troškova održavanja te prosječni godišnji nominalni troškovi održavanja	78
Tablica 4.6. Deskriptivna statistika seta podataka	83
Tablica 4.7. Vrijednosti koeficijenta korelacije i njihova tumačenja [271]	88
Tablica 4.8. Razine statističke značajnosti [279], [281]	89
Tablica 4.9. Koeficijenti korelacije neovisnih i ovisnih varijabli	92
Tablica 4.10. Statistički značajne nezavisne varijable za izradu modela procjene troškova održavanja	93
Tablica 4.11. Prijedlog varijabli modela troškova održavanja s jednom varijablom	93
Tablica 4.12. Prijedlog varijabli modela procjene troškova održavanja s dvije varijable	94
Tablica 4.13. Prijedlog varijabli modela procjene troškova održavanja s tri varijable	94
Tablica 4.14. Chaddockova ljestvica [297], [298]	95
Tablica 5.1. Nazivi modela s jednom nezavisnom varijablom	97
Tablica 5.2. Nazivi modela s dvije nezavisne varijable	98

Tablica 5.3. Nazivi modela s tri nezavisne varijable	98
Tablica 5.4. Vrijednosti MAE i AIC za predložene modele.....	100
Tablica 5.5. Podatci za model s interakcijom (model 15).....	101
Tablica 5.6. Varijable modela procjene troškova održavanja s pripadajućim podacima	104
Tablica 5.7. Sažeti tablični prikaz razvijenih modela	108
Tablica 5.8. Podatci o kanalizacijskom sustavu namijenjenom za validaciju	109
Tablica 5.9. Rezultati validacije modela I na testnom uzorku	111
Tablica 5.10. Rezultati validacije modela II na testnom uzorku.....	111
Tablica 5.11. Rezultati validacije modela III na testnom uzorku	112
Tablica 5.12. Rezultati validacije modela IV na testnom uzorku	112

POPIS KRATICA I SIMBOLA

A	Any (hrv. bilo koja, svaka)
α	razina značajnosti
AC	Asbestos cement (hrv. azbest cement)
Ac	Model Accuracy (hrv. točnost modela)
AHP	Analytic Hierarchy Process (hrv. analitičko-hijerarhijski proces)
AIC	Akaike information criterion (hrv. Akaikeov informacijski kriterij)
APOGEE	Analyses et Programmation Optimise pour la Gestion, L'Entretien et L'Exploitation du Reseaux d'Assainissement (hrv. analiza i optimalno programiranje upravljanjem, održavanjem i upotrebom kanalizacijske mreže)
ASCE	American Society of Civil Engineers (hrv. Američko udruženje građevinskih inženjera)
Br	Brick (hrv. opeka)
C	Concrete (hrv. beton)
CCTV	Closed-circuit television (hrv. snimanje kamerama, televizijska inspekcija)
CI	Cast iron (hrv. lijevano željezo)
CIPP	Cured-In-Place Pipe (hrv. metoda sanacije u mjestu)
CL	Clay (hrv. glina)
ES	Expert system (hrv. ekspertni sustav)
FM	Facility Management (hrv. gospodarenje građevinama)
FOG	Fats, oils, and grease (hrv. masti i ulja)
GIS	Geographic information system (hrv. geografski informacijski sustav)
HDPE	High-density polyethylene (hrv. polietilen visoke gustoće)
I/I	Infiltration and inflow (hrv. infiltracija podzemne vode i utjecanje oborina)
IAWD	International Association of Water Supply Companies in the Danube River Catchment Area (hrv. Međunarodno udruženje poduzeća za opskrbu vodom za područje dunavskog sliva)

IFMA	The International Facility Management Association (hrv. Međunarodna udruga za upravljanje građevinama)
LCCA	Life cycle cost analysis (hrv. analiza troškova životnog ciklusa)
MAE	Mean absolute error (hrv. srednja apsolutna pogreška)
MOGA	Multi-objective genetic algorithm (hrv. višekriterijski genetski algoritam)
MSCC4	Method of Sewer Condition Classification (hrv. metoda klasifikacije stanja kanalizacije)
N.D.	Not defined (hrv. nije definirano)
NKD 2007.	Nacionalna klasifikacija djelatnosti 2007.
NM	nemetalno
NN	Narodne novine
PCCP	Pre-stressed cylindrical concrete pipe (hrv. prednapregnuta betonska kružna cijev)
PVC	PVC plastic (hrv. polivinilklorid)
R^2	koeficijent determinacije
RFEC	Remote Field Eddy Current (hrv. ispitivanje pomoću elektromagnetskog strujnog polja)
S	Steel (hrv. čelik)
SAD	Sjedinjene Američke Države
SASW	Spectral analysis of surface waves (hrv. spektralna analiza površinskih valova)
SCRAPS	Sewer Cataloging, Retrieval and Prioritization System (hrv. sustav za katalogizaciju kanalizacije, davanje podataka i prioritizaciju)
SPSS	Statistical Package for the Social Sciences (hrv. statistički paket za društvene znanosti)
TMI	Thornthwaite Moisture Index (hrv. Thornthwaite indeks vlažnosti)
UN	United Nations (hrv. Ujedinjeni narodi)
UPOV	uređaj za pročišćavanje otpadnih voda
US GAO	United States General Accounting Office (hrv. Generalni računovodstveni ured Sjedinjenih Američkih Država)

1. UVOD

1.1. Predmet istraživanja

Obilježje današnjice u svijetu je porast broja stanovništva i naseljavanje u urbanim sredinama te stvaranje velikih urbanih sredina – megapolisa. Mogućnosti odvodnje otpadnih voda u takvim sredinama su različite i ovise o većem broju parametara [1]. Brzi rast populacije i visok stupanj migracije u urbana područja stvara veliku i neplaniranu urbanizaciju [2] te tako povećava pritisak na infrastrukturu naselja [3]. Kako je ubrzan porast stanovništva na Zemlji, a samim tim i potrebe stanovništva za vodom za život i rad, ona postaje važan faktor za brigu o očuvanju voda. Pitka je voda neophodna za ljudski život, zdravlje i ukupnu dobrobit, odnosno za smanjenje siromaštva i gladi. Voda je ključni element održivog razvoja, predstavlja globalnu materiju koja bitno utječe na razvoj ili propast života na Zemlji. Zbog trenda koncentracije stanovništva u gradovima može se bez pretjerivanja reći da će i njihovo funkcioniranje ovisiti o količini i kvaliteti upravljanja i raspodjele vodnim resursima unutar gradova [4] te će rizici povezani s vodom biti sve više koncentrirani u gradovima [5].

Urbanom izgradnjom sve se više prirodnog terena pretvara u nepropusne slivne plohe koje imaju koeficijent otjecanja blizu jedan, što donosi veću količinu oborina u kanalizacijski sustav [6] tako povećavajući njegovo opterećenje.

Rezolucijom Opće skupštine UN-a 64/292 iz 2010. godine potvrđeno je pravo na sigurnu i čistu vodu za piće i odvodnju otpadnih voda kao ljudsko pravo od ključne važnosti za potpuno uživanje života i svih ljudskih prava [7], [8]. Svima moraju biti osigurane i lako dostupne dovoljne količine vode [9].

Pouzdana infrastruktura osnova je za socioekonomski razvoj države. Fenomen starenja materijala i prirodne nepogode predstavljaju velik rizik i utjecaj na građevine i infrastrukturu. Starenje zbog različitih utjecaja iz okoliša smanjuje sigurnost i pouzdanost postojećih građevina i infrastrukture [10], a čiji je dio i kanalizacijski sustav. Kanalizacijski sustav osnovna je gradska infrastruktura za očuvanje javnog zdravlja. Izgradnja kanalizacijskog sustava zahtijeva velike količine novčanih sredstava i rada [11]. Također, o važnosti kanalizacijskog sustava kao infrastrukturnog govori i činjenica da je kanalizacijski sustav kao dio komunalnih vodnih građevina koje pripadaju u sektor vodnog gospodarstva proglašen

kritičnom infrastrukturom što je navedeno u članku 4. Zakona o kritičnim infrastrukturama (NN 56/13) [12].

S porastom broja stanovnika u gradovima kao posljedica industrijske revolucije u 19. stoljeću uočava se da više nije moguće otpadnu, korištenu vodu ispuštati bez pročišćavanja u prirodni okoliš te počinje razvoj postrojenja za obradu otpadnih voda [13]. U današnje vrijeme sa sve većim porastom broja stanovnika i razvojem industrije, na svjetskoj razini, rastu i količine otpadnih voda [14].

Nekada je postojalo shvaćanje da je vodovod osnovna potreba, a kanalizacija luksuz, međutim takvo mišljenje je odavno napušteno, iako još negdje ima takvih razmišljanja [15]. Kanalizacijski sustavi stoljećima su bili u funkciji javnog zdravlja stanovništva i velikim dijelom su odgovorni za potporu kontinuiranog ekonomskog rasta [16]. Porastom urbanizacije, upravljanje otpadnim vodama postaje sve važnije u održivom razvoju zajednice [17]. Kanalizacijski sustav jednako je važan kao vodoopskrbni sustav, kako u smislu razvoja, tako i u smislu financijskog utjecaja [18]. U godinama koje dolaze očekuje se da će pročišćavanje otpadnih voda postati veliki problem razvoja [19]. Većina gradova suočava se s problemom starenja infrastrukture te potrebom njezinog održavanja, obnove ili zamjene [20]. Zbog prethodno navedenoga, važno je planirati, predvidjeti i upravljati svim troškovima održavanja koji nastaju tijekom životnog vijeka kanalizacijskih sustava. U članku 9. Zakona o vodnim uslugama je navedeno kako su „komunalne vodne građevine javna dobra u javnoj uporabi i u vlasništvu su javnoga isporučitelja vodnih usluga na uslužnom području“ [21], a u komunalne vodne građevine ubraja se i kanalizacijski sustav kao sustav za javnu odvodnju [22], [23]. Budući da je javna odvodnja vodna usluga (uz uslugu javne vodoopskrbe) [21] te se troškovi upravljanja komunalnim vodnim građevinama, uključujući održavanje komunalnih građevina i troškove poslovanja javnih isporučitelja vodnih usluga, financiraju iz cijene vodne usluge, važno je o svim troškovima voditi računa. Krajnji korisnici plaćaju navedeno te jedan od ciljeva treba biti smanjenje troškova održavanja kanalizacijskih sustava. Nadalje, u članku 5. Zakona o vodnim uslugama (NN 66/19) stoji da se „djelatnosti vodnih usluga obavljaju trajno, učinkovito, ekonomično i svrhovito, da se obavljaju tako da se osigura njihov održivi razvitak i stalno povećanje kakvoće vodnih usluga te da se komunalne vodne građevine održavaju trajno u stanju funkcionalne ispravnosti“ [21]. Stoga, obveza svih je voditi računa o održavanju kanalizacijskih sustava.

Čovjek svojim radom i životom stvara različita zagađenja čvrstog i tekućeg podrijetla. Jedna od tih zagađenja su otpadne vode [24]. Otpadne vode nastaju upotrebom vode iz vodoopskrbnog sustava za raznovrsne namjene tako da im se mijenja kakvoća u smislu promjene prvotnih fizikalnih, kemijskih i mikrobioloških značajki [25], [26]. Prema Zakonu o vodama (NN 66/19, 84/21), otpadne vode definiraju se kao „sve potencijalno onečišćene industrijske, sanitarne, oborinske i druge vode“ [22], [23].

Troškovi održavanja građevina su često zanemarivani budući da ih je relativno teško izračunati i predložiti potencijalnom investitoru s obzirom na to da se događaju u budućnosti. Najčešće je investitor usmjeren na troškove koji se pojavljuju odmah – to su troškovi građenja koji se izračunavaju u troškovniku i na koje svi prvo pomisle kada se govori o troškovima građevine. Stoga se sva pažnja investitora i svih sudionika u gradnji usmjeravala na smanjenje troškova građenja, dok je malo sudionika posvećivalo pažnju smanjenju troškova održavanje i uporabe građevina ili, što je još važnije, smanjenju ukupnih troškova projekata [27]. Do 1960-ih godina mnogo je investitora donosilo investicijske odluke samo na bazi kapitalnih troškova. Posebno su se u javnom sektoru troškovi dijelili na kapitalne troškove i ponavljajuće troškove (npr. troškovi održavanja) budući da je bilo važno izgraditi građevinu uz najniže moguće kapitalne troškove u nadi da će se kasnije pronaći novčana sredstva koja će trebati za troškove održavanja i uporabe koji mogu i porasti [28].

Budući da je u današnje vrijeme, više nego ikada, naglašena nestašica resursa koji se koriste u gradnji građevina, broj stanovnika vrlo brzo raste, naglašena je povećana urbanizacija i gradnja novih građevina. Nove građevine zauzimaju obradive površine ili površine koje su bile pod zelenilom te je važno promišljati o aktivnostima održavanja postojećih građevina, i težiti k smanjenju gradnje novih građevina, naravno, u mjeri koliko je to moguće. Potrebno je štedljivo i pametno koristiti sve resurse koje čovjek ima na raspolaganju, pažljivo graditi građevine u smislu promišljanja o vrstama materijala koje se koriste, o pravilnoj izvedbi zamišljene, odnosno projektirane građevine, pravilnoj uporabi građevine – uporabi građevine s onom svrhom s kojom je projektirana i izgrađena, te na kraju, kada dođe kraj uporabnog vijeka, o pravilnom odlaganju otpada od srušene građevine.

Međutim, za bilo koju vrstu realizacije projekta gradnje građevina, od velike su važnosti financijski resursi. Bez dostatnih financijskih resursa nema mogućnosti odabira materijala s kojima će se graditi, nije moguće predložiti više varijantnih rješenja neke građevine ili bilo što drugo. U početku, dok se građevina vizualizira, tj. projektira, moguće je izračunati i predvidjeti

troškove gradnje građevine što se uobičajeno radi u troškovniku. U troškovniku je za sve pozicije radova izračunata cijena te je tako moguće, uz određene pretpostavke, izračunati cijenu gradnje građevine. I uz takvu mogućnost, naoko točnog izračuna količina i cijene radova, događaju se, nerijetko, veliki promašaji u izračunu cijene građenja – obično se izračunata cijena premaši. Većinu investitora ili sudionika u gradnji koji direktno sudjeluju u gradnji ili financiranju iste zanimaju samo ti početni troškovi građenja. No troškovi građenja nisu jedini troškovi koji se pojavljuju u životnom vijeku građevine. Ostali troškovi koji se javljaju su svakako troškovi uporabe i troškovi održavanja te se oni (troškovi održavanja) često zanemaruju kod odlučivanja između različitih varijantnih rješenja građevina. Stoga, dok se građevina koncipira i projektira te odabiru varijantna rješenja, važno je imati na umu troškove održavanja i uporabe. Tijekom faze projektiranja građevine u proračun troškova potrebno je osim troškova gradnje ukalkulirati i troškove održavanja i uporabe.

Kod gradnje infrastrukturnih projekata – građevina poput vodoopskrbnog sustava, kanalizacijskog sustava i elektroenergetskog sustava gleda se, uobičajeno, cijena gradnje neke građevine u sklopu tog infrastrukturnog sustava. Što se tiče održavanja kao i promišljanja o cijeni održavanja, to se zanemaruje u fazi koncipiranja i građenja građevina. Međutim, takav način razmišljanja je pogrešan način te dovodi do povećanih troškova održavanja, nemogućnosti izračuna – predviđanja potrebnih financijskih resursa potrebnih za održavanje, lošeg rada sustava i problema koji se javljaju korisnicima tog sustava. Jasno je da ako se aktivnosti održavanja uopće ne planiraju, onda je jako teško i za njih osigurati potrebne financijske resurse. Ako financijski resursi nisu osigurani, onda nije moguće provesti pravilno održavanje ili ga uopće nije moguće provesti. Također, ako se promotri infrastrukturni sustav poput kanalizacijskog sustava koji ide ispod tla, onda je redovito održavanje jako važno jer se gradnjom novog kanalizacijskog sustava ili neplaniranim popravcima uništavaju svi slojevi iznad cijevi (npr. asfaltbeton na ulici, pločnici, ozelenjene površine) te su zbog toga gradnja i popravak takvih sustava još dodatno skuplji za iznos koji je potrebno uložiti za vraćanje slojeva iznad kanalizacijskih cijevi u prvobitno stanje.

Procjenjuje se da se u Europi godišnje oko 50 % budžeta namijenjenog za građenje potroši na troškove, odnosno radove popravaka konstrukcija [29], [30]. U Ujedinjenom Kraljevstvu godišnji troškovi za popravke, održavanje i zamjene kod građevinske infrastrukture zahtijevaju velika novčana sredstva [31]. SAD troši oko 18 do 20 bilijuna dolara na održavanje, popravke i zamjenu dotrajale infrastrukture [32].

Procjena troškova na razini životnog ciklusa je jako važna kod infrastrukture gdje kapitalni troškovi mogu biti visoki, a i uštede ostvarene tijekom godina uporabe i održavanja također mogu biti dosta velike. Troškovi uporabe i održavanja su visoki te predstavljaju velik udio u ukupnim godišnjim troškovima što otvara mogućnosti za značajne uštede [33].

Istraživanje provedeno od strane US GAO je pokazalo da 65 % poduzeća koja se bave upravljanjem odvodnjom ne ostvaruje planirani i željeni stupanj zamjene ili obnove cijevi kanalizacijskog sustava zbog nedovoljno sredstava. Odnosno, to znači da 65 % planova održavanja i obnove nije provedeno, odnosno provedeno je ispod očekivanog stupnja održavanja i obnove zbog nedostatka sredstava [34].

Kanalizacijski sustav zajedno s vodoopskrbnim sustavom svrstava se u komunalnu hidrotehniku, odnosno u gradski tehnički sustav kao infrastrukturu naselja [35]. Jedan od najvažnijih infrastrukturnih sustava nekog grada je kanalizacijski sustav. On pomaže održavanju zdravlja ljudi nekog grada i preduvjet je komunalne higijene [36]. Već je to dovoljno da se vidi njegova važnost. Budući da je od velike važnosti, potrebno ga je pravilno održavati. Kako je već prije navedeno, da bi se bilo što, pa tako i kanalizacijski sustav, moglo održavati, potrebno je prije svega imati na umu aktivnosti održavanja, a nakon toga i predvidjeti u proračunu određena novčana sredstva za tu svrhu. Potrebno je dakle na vrijeme planirati novčana sredstva za održavanje, pa čak i ako ona trenutno nisu dostatna za zadovoljavanje svih potreba održavanja, jer opet se određeni, kritični dio može održavati i popraviti. Jasno, teško je točno predvidjeti novčane resurse za događanja u budućnosti jer se budućnost ne može niti će se ikad moći predvidjeti. Ali, iako je teško, ne smije se to zanemariti i prepustiti slučaju.

Sustavi odvodnje zahtijevaju velika novčana ulaganja. A, kako bi se opravdala ta velika ulaganja i osigurao redoviti rad kanalizacijskog sustava, takvim se sustavima mora pravilno upravljati i održavati ih, uz dostatno financiranje i kontrolu [37]. Kako postrojenja za pročišćavanje otpadnih voda i kanalizacijski sustavi dolaze do kraja životnog vijeka, tako financijska sredstva potrebna za uporabu i održavanje postaju sve veća [38]. Prema procjeni Američkog udruženja građevinskih inženjera (engl. *American Society of Civil Engineers*, ASCE) očekuje se da će se 56 milijuna novih korisnika spojiti na centralizirane sustave za pročišćavanje otpadne vode u sljedećih 20 godina, te se procjenjuje da će trebati 271 bilijun dolara kako bi se zadovoljile sadašnje i buduće potrebe [38], [39].

Istraživanjem problematike u području održavanja građevina svih vrsta uočen je niz problema i nedostataka. Prije svega, literature koja obrađuje navedenu problematiku je relativno malo.

Literatura koja postoji je većinom teorijska budući da nedostaje stvarnih podataka o troškovima održavanja bilo kojih vrsta građevina koji bi, kada bi ih bilo više, omogućili izradu boljih i točnijih modela za procjenu troškova održavanja. Značajan je nedostatak znanja o problematici održavanja kanalizacijskih sustava i pripadajućim troškovima, koji bi služili kao temelj za procjenu troškova održavanja kanalizacijskog sustava u budućnosti. Kako bi se procijenili troškovi održavanja kanalizacijskog sustava, potrebno je prije svega imati kvalitetne i točne podatke o njegovom održavanju. Međutim, kako su kanalizacijski sustavi u javnom upravljanju pod različitim jedinicama lokalne i regionalne samouprave, iste ne vode pravilno evidenciju o troškovima održavanja kanalizacijskih sustava za određena razdoblja i stavkama održavanja. Također, neka javna poduzeća koja upravljaju kanalizacijskim sustavom su propala ili se spojila s drugim poduzećima, dobila nove rukovodeće djelatnike, promijenila se struktura upravljanja što je posljedično dovelo da povećane mogućnosti da se podatci izgube, zaborave ili jednostavno nestanu. Nadalje, obično jedno poduzeće upravlja vodoopskrbnim i kanalizacijskim sustavom te je time još više otežano dobivanje podataka o troškovima održavanja kanalizacijskih sustava. U tom slučaju, kada jedno poduzeće upravlja vodoopskrbnim i kanalizacijskim sustavom, troškove je teže evidentirati prema mjestu nastanka troška. Ako su manja poduzeća u pitanju, onda obično nemaju razdvojene poslovne jedinice za vodoopskrbu i poslovnu jedinicu za odvodnju; za neke troškove kao što je trošak rada određenog stroja (npr. bager koji se koristi za poslove građenja i održavanja vodoopskrbnog, ali i kanalizacijskog sustava) je teško definirati koliko točno goriva je utrošeno za koji posao. Razloga ima još, međutim iz prethodno nekoliko navedenih vidi se složenost problematike razdvajanja troškova. I, još važnije, poznato je da se sve što ima veze s novcem smatra poslovnom tajnom i poduzeća su vrlo oprezna i ne žele javno dijeliti podatke o troškovima. To je, između ostalih, jedna od najvećih zapreka zašto nedostaje podataka o troškovima održavanja koji su preduvjet za izgradnju modela za procjenu troškova održavanja.

Kada bi se model za procjenu troškova životnog ciklusa (pa samim time i održavanja) primjenjivao, to bi uvelike olakšalo donošenje odluka investitorima i svim dionicima. Naravno, da bi se model primjenjivao, potrebno je da taj model postoji, kao i da bude provjeren – validiran na određenom (dovoljnom) broju stvarnih slučajeva – podataka. Jedan od dijelova životnog ciklusa je i ciklus održavanja građevine. Gradnja građevine može trajati određeno vrijeme, više ili manje dugo, ali faza uporabe, a samim time i održavanja građevine, traje sigurno dulje od faze građenja. Faza održavanja građevine može i treba trajati onoliko koliko je uporabni vijek građevine (npr. 30 do 50, a i više godina, ovisno o vrsti građevine). Stoga, da

se zaključiti da je faza održavanja vrlo duga te samim time zahtijeva velike financijske resurse koji su obično veći od troškova gradnje građevine. Naravno da navedeno ovisi o vrsti građevine – treba svakako razlikovati stambene zgrade, višestambene zgrade od mostova, prometnica ili ostalih infrastrukturnih građevina.

U provođenju istraživanja u svrhu izrade doktorske disertacije važnu ulogu imala je analiza znanstvenih članaka koji obrađuju problematiku održavanja građevina, a posebno održavanje i troškove održavanja kanalizacijskih sustava. U proučenoj literaturi uočeno je da, kao što je prije navedeno, nedostaje, odnosno nema podataka o troškovima održavanja kanalizacijskih sustava. Također, u dostupnoj i analiziranoj literaturi nije uočen ni jedan konkretni model za procjenu troškova održavanja kanalizacijskog sustava. Što se tiče modela za procjenu troškova održavanja ostalih građevina poput škola, uredskih zgrada, mostova, zgrada sveučilišta i sl., uočeno je da istih ima, ali opet u nedovoljnoj mjeri koja bi omogućila procjenu troškova tih građevina u što većoj mjeri i sa što boljom točnošću.

U Republici Hrvatskoj ne postoji istraživanje koje se bavi modelom procjene troškova održavanja kanalizacijskih sustava te ne postoji baza podataka o troškovima održavanja kanalizacijskih sustava koja bi omogućila izradu navedenog modela. Pregledom literature utvrđeno je da ne postoji model za procjenu troškova održavanja kanalizacijskog sustava. Izradom i primjenom modela procjene troškova održavanja kanalizacijskog sustava uvelike bi se unaprijedila učinkovitost budući da bi to olakšalo određivanje budžeta poduzećima koja upravljaju kanalizacijskim sustavom.

Pregled literature sadrži najnovija istraživanja u području održavanja građevina, troškovima održavanja i modelima za procjenu/predviđanje troškova održavanja građevina. Kako bi se moglo pravilno razmotriti održavanje kanalizacijskog sustava, pregled literature također sadrži opći dio o održavanju kanalizacijskog sustava, vrstama kanalizacijskih sustava te stanju odvodnje i kanalizacijskih sustava u Republici Hrvatskoj.

1.2. Ciljevi i hipoteze istraživanja

Cilj istraživanja u svrhu izrade ove doktorske disertacije je istražiti mogućnost stvaranja modela za procjenu troškova održavanja kanalizacijskog sustava. U radu će se analizirati dostupni podaci o karakteristikama kanalizacijskih sustava kao što su vrsta kanalizacije, duljina kanalizacijske mreže, broj priključaka, broj crpnih stanica, količina otpadne vode te

troškovi održavanja. Kako bi se sve prethodno navedeno moglo razumljivo i pregledno analizirati i komentirati, prikazat će se opći dio o kanalizacijskom sustavu, načinima i tehnologiji održavanja kanalizacijskog sustava. Na osnovi karakteristika i različitih parametara kanalizacijskog sustava dan je prijedlog modela za procjenu troškova održavanja kanalizacijskog sustava.

Osnovna svrha istraživanja u svrhu izrade doktorske disertacije je oblikovanje modela za procjenu troškova održavanja kanalizacijskog sustava koji će dati podlogu za učinkovitije odlučivanje, bolje raspoređivanje resursa, odnosno bolje određivanje potrebnog proračuna za planiranje aktivnosti održavanja kanalizacijskog sustava. Navedeno će najviše koristiti poduzećima koja upravljaju kanalizacijskim sustavima. Kako bi se razvio model, koristit će se povijesni podaci o troškovima održavanja kanalizacijskih sustava koji su bili dostupni autoru u trenutku izrade rada.

Ciljevi ovog rada su sljedeći:

- Istražiti u kojoj je mjeri moguće prikupiti povijesne podatke o karakteristikama kanalizacijskih sustava te troškovima održavanja istih.
- Opisati postojeće probleme i tehnologije održavanja kanalizacijskih sustava.
- Istražiti mogućnosti stvaranja modela procjene troškova održavanja kanalizacijskog sustava za određeno razdoblje
- Istražiti čimbenike – varijable koje utječu na troškove održavanja kanalizacijskog sustava.
- Definirati smjernice za primjenu takvog modela.
- Definirati prednosti i ograničenja takvog modela.
- Dobiti nova znanja na području održavanja kanalizacijskih sustava na temelju prikupljenih podataka i njihove analize koja će omogućiti izradu smjernica i pravila poboljšanja učinkovitosti održavanja kanalizacijskih sustava u Republici Hrvatskoj i njihovu primjenjivost na drugim, sličnim kanalizacijskim sustavima izvan RH.
- Istražiti u kojoj mjeri broj priključaka na kanalizacijski sustav utječe na količinu otpadne vode za određene kanalizacijske sustave naselja s dostupnim podacima o održavanju kanalizacijskih sustava.

- Prepoznati važnost i značaj razvijanja daljnjeg praćenja troškova održavanja kanalizacijskog sustava u funkciji upravljanja cjelokupnim kanalizacijskim sustavom kao jednim od najvažnijih infrastrukturnih sustava naselja.

Radne hipoteze rada glase:

- Moguće je stvaranje baze podataka o troškovima održavanja određenih kanalizacijskih sustava u Republici Hrvatskoj koja će se temeljiti na prikupljenim podacima o povijesnim troškovima održavanja kanalizacijskih sustava.
- Moguće je definirati metodologiju za uključivanje određenih karakteristika kanalizacijskog sustava (npr. duljina kanalizacijske mreže, broj priključaka, količina otpadne vode itd.) i pomoću nje procijeniti troškove održavanja za određeno razdoblje.
- Moguć je razvoj modela za procjenu troškova održavanja kanalizacijskih sustava za potrebe komunalnih poduzeća utemeljenih na povijesnim podacima o troškovima održavanja određenih kanalizacijskih sustava, uz određenu točnost predloženog modela.
- Moguće je utvrditi utjecaj određenih karakteristika – varijabli kanalizacijskih sustava na troškove održavanja sustava.

1.3. Metode i postavke istraživanja

U svrhu izrade doktorske disertacije provedeno je istraživanje usmjereno na održavanje kanalizacijskih sustava i pripadajuće troškove, a za koje ne postoji baza podataka o karakteristikama kanalizacijskih sustava te posebno ne postoje povijesni podatci o troškovima održavanja istih. U istraživanju za potrebe izrade ovog doktorskog rada koristit će se analiza, odabir i provjera dostupnih izvora informacija i literature. Istraživanje obuhvaća pregled i analizu postojeće stručne i znanstvene literature te određenih izvješća koja su vezana za problematiku održavanja i troškove održavanja kanalizacijskih sustava. U svrhu prikupljanja podataka koristit će se anketni upitnik i intervju kao oblik istraživanja o karakteristikama i troškovima održavanja kanalizacijskih sustava te razgovor s rukovodećim zaposlenicima zaduženima za održavanje kanalizacijskog sustava.

U istraživačkom radu primijenit će se kombinacija kvalitativnog i kvantitativnog pristupa. Prvi dio rada bit će temeljen na deduktivnom pristupu te će se temeljiti na pregledu i analizi

postojećih radova dostupnih autoru u trenutku pisanja rada. U tom dijelu predložit će se nove teorije utemeljene na postojećoj literaturi. Detaljnom analizom literature definirat će se i dati struktura troškova održavanja kanalizacijskog sustava koja još, prema saznanjima autora, nije definirana. Vodeći se prethodno navedenim, bit će kreiran upitnik kojim će se prikupiti podaci potrebni za istraživanje od poduzeća zaduženih za javnu odvodnju na području Republike Hrvatske.

Prilikom izrade teorijskog dijela rada koristit će se induktivna i deduktivna metoda te metode analize i sinteze. Kako bi se izradio model za procjenu troškova održavanja kanalizacijskog sustava, koristit će se statističke metode za analizu podataka prikupljenih pomoću upitnika. Taj dio, dio stvaranja modela za procjenu troškova održavanja kanalizacijskog sustava od prikupljenih podataka pomoću upitnika, je induktivni dio istraživanja.

U izradi i oblikovanju modela za procjenu troškova održavanja kanalizacijskog sustava koristit će se programski jezik R te računalni program *Statistica*. Odabrat će se najpovoljniji model u smislu točnosti i jednostavnosti uporabe – korištenja što manje varijabli koje u zadovoljavajućoj mjeri opisuju prosječne troškove održavanja kanalizacijskog sustava. Nakon testiranja modela, koristit će se metoda usporedbe stvarnih (ulaznih) vrijednosti troškova održavanja i dobivenih (izlaznih) vrijednosti troškova održavanja. Koristit će se oni modeli koji imaju najbolje određene pokazatelje, kao što je najmanja srednja apsolutna pogreška (MAE), podešeni R^2 te *Akaikeov* informacijski kriterij (AIC). Validacija modela napraviti će se na prikupljenim podacima za područje Republike Hrvatske.

Radni plan istraživanja i izrade doktorske disertacije opisan je u nastavku.

Prvi korak u istraživanju uključuje detaljan pregled i analiziranje postojeće znanstvene i stručne dostupne literature koja se bavi navedenom problematikom. Cilj pregleda literature je istraživanje trenutnog stanja u području istraživanja vezano za karakteristike kanalizacijskih sustava, njihovo stanje, načine održavanja i troškove održavanja. Tijekom pregleda literature uočen je znatan nedostatak literature koja se bavi općenito održavanjem građevina, dok je literature o održavanju i troškovima kanalizacijskih sustava još manje. Na osnovu pregleda literature napisani su članci „*Prevenција kvarova sprječavanjem rasta i uklanjanjem korijenja drveća u kanalizacijskim cijevima*“ objavljen u časopisu *Vodoprivreda* te rad „*Mogućnosti primjene ekspertnih metoda za optimizaciju održavanja sustava odvodnje*“ objavljen u časopisu *Građevinar*.

Drugi je korak izrada upitnika pomoću kojeg će se prikupljati: opći podatci o komunalnom poduzeću (broj zaposlenih, područje na kojem se obavlja djelatnost odvođenja otpadnih voda, oprema za održavanje), opći podatci o kanalizacijskom sustavu (vrsta kanalizacije, duljina mreže, broj priključaka, broj crpnih stanica), količine otpadnih voda po godinama, dostupni podatci o cijevima (vrste cijevi, duljine itd.) te povijesni podatci o održavanju sustava (troškovi održavanja). Nakon izrade upitnika napraviti će se preliminarni intervjui s komunalnim poduzećima kako bi se vidjelo jesu li upitnici dobro strukturirani budući da je jedan od preduvjeta istraživanja dobivena dovoljna količina kvalitetnih podataka pomoću dobro izrađenih upitnika. Općenito je poznata nezadovoljavajuća evidencija u poduzećima koja upravljaju javnom odvodnjom, a i uočeno je nezadovoljavajuće vođenje evidencije troškova održavanja, loša organizacija i struktura svih gore spomenutih karakteristika i podataka te se već u ovom koraku može pretpostaviti da će prikupljanje podataka biti otežano.

Treći je korak pretraživanje i odabir (manjih, srednjih i većih) komunalnih poduzeća i stvaranje baze podataka o njima – naziva i mjesta poduzeća, prikupljanje kontakata te stupanje s njima u kontakt (*e-mailom*, telefonski ili osobno). Zatim slijedi slanje upitnika i pripadajuće zamolbe za dostavu podataka. Nakon određenog vremena s onim poduzećima koja se nisu izjasnila o dostavi ispunjenih upitnika ponovno će se pokušati stupiti u kontakt uz istu zamolbu, a sve u svrhu prikupljanja što veće količine podataka i konačnog uvida u kvalitetu i količinu istih.

Četvrti je korak prikupljanje i grupiranje dobivenih podataka. Prikupljeni upitnici će se pregledati (koliko su ispunjeni i kvaliteta ispunjenih podataka) te će se kod analiziranja upitnika kontaktirati osobe koje su ih ispunile u slučaju da ima nedoumica i nejasnoća oko ispunjenih podataka. Nakon toga će se napraviti konačni izbor kanalizacijskih sustava koji će se koristiti u daljnjem istraživanju. Očekuje se da će konačan broj kanalizacijskih sustava koji će biti analizirani i korišteni u daljnjem radu iznositi najmanje 12.

Peti korak uključuje obradu i interpretaciju prikupljenih podataka. Nakon obrade prikupljenih podataka pristupit će se interpretaciji rezultata. Kod statističke obrade podataka, ovisno o potrebama, koristit će se dostupni računalni programi: *Statistica* i programski jezik R. Nakon toga izvest će se zaključci o promatranim kanalizacijskim sustavima, njihovim troškovima održavanja, karakteristikama od interesa – parametrima i varijablama koji će se promatrati kod određivanja i procjene troškova održavanja kanalizacijskog sustava. Tako, preliminarno, dobiveni i uočeni parametri koristit će se u daljnjoj analizi i modeliranju, a težinski utjecaj svih

varijabli još će se dodatno provjeriti u idućem koraku izrade modela procjene troškova održavanja.

Šesti je korak istraživanje utjecaja određenih varijabli na troškove održavanja kanalizacijskog sustava. Također, tijekom analize u računalnim programima odredit će se varijable od interesa, odnosno one varijable koje se pokazuju značajnim za procjenu troškova održavanja. Kod određivanja varijabli istražit će se koje varijable imaju veliki utjecaj na troškove održavanja, a koje mali utjecaj. Zatim se planira izrada određenog modela ili više njih u prije spomenutom računalnom programu i programskom jeziku. Nakon toga će se napraviti validacija izrađenog modela te analiza osjetljivosti kako bi se vidjelo kako promjena određenih varijabli modela utječe na promjenu troškova održavanja kanalizacijskih sustava.

Sedmi je korak izrada i obrada završnih rezultata istraživanja, definiranje prednosti i ograničenja modela, smjernica za primjenu takvog modela, pisanje zaključaka te prezentacija najvažnijih rezultata istraživanja. Također, ovaj zadnji dio rada obuhvaća sintezu rezultata.

1.4. Struktura disertacije

Struktura doktorske disertacije oblikovana je prema Uputama za izradu i oblikovanje doktorske disertacije Građevinskog i arhitektonskog fakulteta Osijek, Sveučilišta Josipa Jurja Strossmayera u Osijeku. Budući da ima određenih stručnih pojmova koji su poznati u svom izvornom obliku na stranom jeziku, obično engleskome, oni su dani u tom obliku, ali, naravno, uz dani prijevod na hrvatski jezik. Rad se sastoji od predgovora, sažetka na hrvatskom i engleskom jeziku, sadržaja, popisa slika i popisa tablica, popisa kratica i simbola, glavnog teksta te, na kraju, popisa citirane literature i priloga.

Zbog lakšeg snalaženja i preglednosti samog doktorskog rada, glavni tekst doktorske disertacije podijeljen je u šest poglavlja.

U prvom poglavlju koji je uvodni dio prikazan je predmet istraživanja, navedeni su ciljevi i hipoteze istraživanja, metode i postavke istraživanja te je opisana struktura doktorske disertacije.

U drugom poglavlju dan je pregled dosadašnjih istraživanja o održavanju građevina i troškovima održavanja građevina s posebnim fokusom na pregled postojeće literature koja obrađuje problematiku održavanja i troškova održavanja kanalizacijskih sustava.

U trećem poglavlju daje se kratki uvid u povijest kanalizacijskih sustava, vrste kanalizacijskih sustava, načine održavanja kanalizacijskih sustava te stanje odvodnje i kanalizacijskih sustava u Republici Hrvatskoj. Prikazani su primjeri održavanja kanalizacijskog sustava i određenih alata i strojeva koji se koriste u održavanju.

Četvrto poglavlje odnosi se na prikupljanje i obradu podataka koji su neophodni za razvoj modela procjene troškova održavanja kanalizacijskih sustava. Prvi dio četvrtog poglavlja prikazuje i analizira upitnik koji je sastavljen kako bi se dobili podatci o kanalizacijskim sustavima. Drugi dio četvrtog poglavlja prikazuje odaziv na anketu te prikupljene podatke. Treći dio četvrtog poglavlja prikazuje analizu odgovora na tri pitanja iz upitnika koja su važna u kontekstu održavanja kanalizacijskih sustava. Zadnji dio četvrtog poglavlja prikazuje osnovnu statističku obradu podataka. Na temelju osnovne statističke obrade podataka odabrana je statistička metoda u definiranju modela te preliminarno odabrane varijable koje će se koristiti u formiranju modela procjene troškova održavanja.

Peto poglavlja rada, s obzirom na složenost sadržaja i potrebu jasnog strukturiranja, obuhvaća najveći broj potpoglavlja. Ono prikazuje razvoj modela procjene troškova održavanja kanalizacijskog sustava te njegovu validaciju. Prije svega, napravljeno je nekoliko modela te je analizirano koji je model najpovoljniji s obzirom na promatrane pokazatelje točnosti i reprezentativnosti modela (srednja apsolutna pogreška, podešeni R^2 i *Akaikeov* informacijski kriterij) i najtočniji u procjeni troškova održavanja. Nakon izrade modela napravljena je validacija modela. Za odabrane modele koji imaju zadovoljavajuće prethodno navedene pokazatelje i koji su prikladne točnosti napravljena je analiza osjetljivosti kako bi se vidjelo kako promjena određenih ulaznih varijabli utječe na promjenu troškova održavanja. Podatci koji su korišteni za validaciju su oni koji su dobiveni pomoću upitnika na području Republike Hrvatske. Primjenjivost modela analizirana je pomoću prikupljenih podataka te je analizirana primjenjivost modela za povećanje učinkovitosti održavanja kanalizacijskih sustava. Također, u ovom su poglavlju definirana ograničenja modela procjene troškova održavanja kanalizacijskog sustava.

Šesto je poglavlje zaključno poglavlje rada gdje su dani zaključci rada, znanstveni doprinos istraživanja i smjernice za daljnja istraživanja.

Na kraju rada nalazi se popis korištene literature.

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA O ODRŽAVANJU GRAĐEVINA I TROŠKOVIMA ODRŽAVANJA GRAĐEVINA

2.1. Gospodarenje građevinama

Kako bi se mogao detaljno opisati problem održavanja kanalizacijskih sustava i gospodarenja kanalizacijskim sustavima, u ovom poglavlju se daje kratki pregled o gospodarenju građevinama, a tako i kanalizacijskim sustavima.

Pojam gospodarenja građevinama ili cjelovitog upravljanja građevinama (engl. *Facility Management*, FM) prvi se put pojavljuje krajem 1960-ih godina u Sjedinjenim Američkim Državama [40], [41]. Slična tumačenja engleske riječi (engl. *facility*) odnosno množine (engl. *facilities*) mogu se naći u različitim englesko-hrvatskim rječnicima. Prema [42] engleska riječ *facilities* znači olakšice, prednosti, odnosno uređaji ili građevine. Slično se navodi u [43], gdje je naveden nešto širi popis odgovarajućih hrvatskih pojmova kao olakšice, mogućnosti, uvjeti, sredstva, oprema, uređaji, instalacije, postrojenja, građevine, ustanove i smještaj. Kao objašnjenje pojma *facility*, u prijevodu s engleskog jezika, stoji da je to izgrađena okolina (sredina) uspostavljena da služi svrhama povezanim s radom [40].

Gospodarenje građevinama može se definirati kao skup trajnih aktivnosti koje sadrže tehnička i pridružena druga, administrativna djelovanja kako bi se tijekom uporabnog vijeka cijeloj građevini i svim njezinim dijelovima osigurala razina služnosti u dostupnim (zadovoljavajućim) granicama [44], [45]. Vidljivo je da gospodarenje građevinama postaje jako važan čimbenik u građevinarstvu [46]. Svrha gospodarenja građevinama je upravljanje građevinama, analiziranje učinkovitosti upravljanja i održavanja građevina, zadržavanje razine vrijednosti građevina te, na kraju, smanjivanje investicijskih ulaganja. Cjelovito gospodarenje građevinama predstavlja integrirani pristup održavanju, prilagođavanju i poboljšanju građevine koji je potreban za ostvarivanje glavnih ciljeva organizacije. Radi se o multidisciplinarnoj djelatnosti koja objedinjuje potporne servise potrebne za gospodarenje građevinama i nesmetano provođenje osnovne djelatnosti organizacije [47].

U pogledu konkretnih definicija International Facility Management Association (IFMA) definira gospodarenje građevinama kao multidisciplinarnu struku koja osigurava funkcionalnost izgrađenog prostora kombiniranjem podataka o ljudima, mjestima, procesima i


tehnologijama [48]. Uloga gospodarenja građevinama je integracija zaposlenika, radnih procesa i radnih mjesta u cjelovit, koherentan i učinkovit sustav [49].

Gospodarenje građevinama je interdisciplinarno zanimanje izgrađeno od teorije i principa inženjerstva, arhitekture, računovodstva, financija i menadžmenta u upravljanju imovinom i svim popratnim sadržajima koji ne čine osnovnu djelatnost tvrtke. Gospodarenje građevinama podrazumijeva nekoliko poslovnih aktivnosti vezanih uz imovinu, a to su: upravljanje fizičkom dugotrajnom imovinom te njeno tehničko i higijensko održavanje (*Operation Management and Maintenance*), upravljanje ugostiteljskim poslovanjem (*Catering Management*), voznim parkom (*Fleet Management*), uredskim prostorom (*Space Management*), arhivskom i registarskom građom, bibliotekom te svim ulaznim i izlaznim dokumentima [41]. Dave Armstrong, jedan od važnijih članova Facility Management instituta, kod mnogih je prepoznat kao neslužbeni „otac“ gospodarenja građevinama [50].

Važnost gospodarenja građevinama za učinkovito upravljanje organizacijskim sustavom danas je tolika da se u razvijenim gospodarstvima poslovni informacijski sustavi u pravilu implementiraju odmah kao cjelovita rješenja, dakle uključujući i gospodarenje građevinama [40].

Kada se promatra gospodarenje građevinama, vidi se više zahtjeva koje je potrebno zadovoljiti. Tu se postavljaju zahtjevi ograničenog budžeta, potrebno je zadovoljiti određene standarde, sve veći broj zakonskih propisa te stupanj prihvaćanja javnosti [51]. Navedeno je isto primjetno kod gospodarenja kanalizacijskim sustavima. Svaki se dan pred održavatelje kanalizacijskih sustava stavlja određeni uvjeti i zahtjevi koji se najlakše mogu prikazati slikom 2.1. Neki izazovi i ograničenja su ograničeni budžet budući da se rijetko kada predviđa određeni budžet za održavanje. Tako ako budžet nije unaprijed izračunat ili procijenjen, nije dostatan. Nadalje, suočava se s društvenim pritiscima kako bi uporaba kanalizacijskog sustava bila bez prekida u radu, bez smetnji. Pred poduzeća koja upravljaju kanalizacijskim sustavima postavljaju se sve veći zakonski zahtjevi – npr. potrebno je zadovoljiti određene parametre pročišćene otpadne vode koje se ispuštaju u prijamnik (rijeku), te se teži sve većoj učinkovitosti u svakom pogledu. Sve to je međusobno isprepleteno preko zaposlenika, sposobnosti, kulture korisnika, različitih procedura, standarda i propisa, raspoloživih podataka i sl.

Na slici 2.1. prikazani su izazovi unutar aktivnosti gospodarenja građevinama.



Slika 2.1. Izazovi unutar aktivnosti gospodarenja građevinama [51]

Upravljanje imovinom (inspekcija, održavanje te popravak ili zamjena) infrastrukture predstavlja složen višedimenzionalni problem i predstavlja aktualnu temu za mnoge gradove zbog ograničenog proračuna, zahtjeva u pogledu očuvanja okoliša, smanjenja rizika [52].

2.2. Životni ciklus i održavanje građevine


Kada se govori o životnom ciklusu građevine, jako je važno spomenuti vrijednost informacija koje su svim dionicima projekta, odnosno ponajviše projektantima građevine, na raspolaganju. Projektanti građevine prvi su koji se susreću s građevinom, koji računaju troškove građenja, a trebali bi računati i troškove održavanja građevina, ali to uobičajeno nije slučaj.

Na slici 2.2. prikazana je vrijednost informacija kroz vrijeme. Ona pokazuje da je najvrjednija informacija ona koja se koristi za procjenu, za previđanje. Zatim, prema važnosti dolazi informacija u realnom vremenu koja također ima značajnu vrijednost koja se smanjuje kako vrijeme prolazi te gubi na značenju i važnosti u razdoblju nakon uporabe [53].

Informacija na početku je jako važna, ali nije 100 % točna, a ni ne može biti jer je za nju i njezino formiranje dostupno malo informacija koje su veoma ograničene, ali bez obzira na to


ima najveću vrijednost. Navedeno je primjenjivo na novčani iznos potreban za održavanje kanalizacijskog sustava jer ako se raspolaze informacijom o budućem budžetu potrebnom za održavanje, to je od velike važnosti pošto je moguće održavati kanalizacijski sustav redovito i pravilno. Takvo je održavanje puno učinkovitije nego ako se potreban budžet za održavanje određuje trenutno, odnosno kada nastupi neki kvar. Tada takva informacija o potrebnom novcu više nema nikakvu vrijednost kao informacija jer se novčana sredstva za popravak moraju odmah naći.

Promatrajući prikazanu sliku 2.2. vidi se koja je važnost mogućnosti predviđanja ili procjene troškova u životnom ciklusu građevine. Kako se navodi u [54], informacija ima svoju vrijednost te je ona ekonomsko dobro, što je samo još jedna potvrda koliko točna i prava informacija u pravo vrijeme puno vrijedi.



Slika 2.2. Vrijednost informacije kao funkcija vremena (prilagođeno prema: [53])

Kada se govori o životnom ciklusu građevine, najlakše i najjasnije ga je prikazati pomoću slike 2.3. Na slici se vidi kako faza održavanja građevine od svih navedenih faza životnog ciklusa građevine traje najdulje. Tako i kod kanalizacijskog sustava faza uporabe, odnosno održavanja traje najdulje, odnosno traje onoliko dugo koliki je životni vijek određenih elemenata kanalizacijskih sustava. Faza uporabe kanalizacijskog sustava traje i puno više od dolje navedenih 30 do 50 godina, međutim to je uobičajeno razdoblje za standardne građevine kao što su stambene zgrade, javne zgrade i sl.




Slika 2.3. Životni ciklus građevine [55]

Održavanje građevina sastavni je dio cjelovitog gospodarenja građevinama. Ono se definira kao poduzimanje svih potrebnih aktivnosti kako bi se održao ili unaprijedio svaki dio građevine, a u svrhu očuvanja vrijednosti i namjene za koju je građevina, odnosno imovina izgrađena. Kako bi se moglo raditi održavanje, potrebno je analizirati uzroke kvarova, te na temelju analize odlučiti o mjerama koje će se poduzeti kako bi se spriječio uzrok [47].

Iako ima jako puno različitih definicija održavanja građevina, najjednostavnija (i vjerojatno najkraća) govori da je održavanje građevine osiguranje stanja građevine prikladnog za uporabu [56]. Naravno da bi bilo jako poželjno imati građevinu koju ne treba održavati, no to je teško izvodljivo. Kako bi se osiguralo da građevina bude prikladna za uporabu, ona se mora održavati prema određenim standardima. Tako troškovi održavanja uključuju sve troškove popravaka koji se javljaju svaki dan, kao i preventivne radove te poslove na poboljšanju elemenata građevine. To su direktni troškovi održavanja. Međutim, osim tih direktnih troškova održavanja postoje i indirektni troškovi kao što su kazne jer građevina nije dostupna za uporabu ili to može biti gubitak vrijednosti građevine [56].

Pojednostavljeno, održavanje građevina može se promatrati kao periodično propadanje i periodično obnavljanje građevine u određenim vremenskim intervalima. Ovakav scenarij životnog ciklusa je pojednostavljen i idealiziran [55]. Tako i kanalizacijski sustav periodično propada te ga je potrebno održavati i raditi potrebne popravke i obnove kako bi mogao obavljati ono za što je namijenjen. Kada se kanalizacijski sustav ne bi redovito održavao, on bi propao te više ne bi mogao obavljati svoju funkciju ili bi je obavljao vrlo loše (npr. pucanje cijevi, curenje otpadne vode, začepjenja, zastoji u uporabi kod korisnika). Na slici 2.4. prikazan je

proces propadanja i popravaka građevina kroz vrijeme. Vremenom i bez održavanja svaka građevina propada te, ako se ne bi provodili popravci i obnove u sklopu aktivnosti održavanja, građevina bi propala te više ne bi udovoljavala minimalnim zahtjevima. Nadalje, na slici je prikazano kako se, u ovom hipotetskom slučaju, obnove i popravci rade svakih 20 godina te se na taj način produžuje vijek trajanja građevine i postiže to da građevina ispunjava sve tražene zahtjeve.



Slika 2.4. Propadanje i održavanje građevina kroz vrijeme [55]

Kod održavanja je potrebno definirati druge bitne pojmove. Prije svega je potrebno definirati dopustive granice razina služnosti i utvrditi standarde održavanja elemenata, građevnih i drugih sklopova i građevina. Standardima se određuje donja dopustiva kvaliteta koju zbog trošenja ili starenja element, sklop i građevina mogu imati, tako da budu zadovoljeni svi temeljni zahtjevi za građevinu (mehanička otpornost i stabilnost, sigurnost u slučaju požara, higijena, zdravlje i okoliš, sigurnost i pristupačnost tijekom uporabe, zaštita od buke, gospodarenje energijom i očuvanje topline te održiva uporaba prirodnih izvora) [57], svi bitni funkcionalni zahtjevi za uporabu (svjetlo, grijanje, hlađenje, čišćenje) te estetski uvjeti i zahtjevi (izgled podova, zidova, stropova, kvaliteta pojedinih elemenata, kvaliteta obloga, kvaliteta i izgled vrata i prozora) [58].

Zatim je potrebno definirati planirano trajanje zgrade, tzv. *life-cycle* koji treba uočiti već u razdoblju kada se projektira zgrada ili bilo koja građevina, zatim u razdoblju građenja, kako bi

se u toj fazi moglo optimizirati s ukupnim ulaganjem u zgradu za vrijeme vijeka trajanja, tzv. *life-cycle cost-a* [58].

Samo održavanje zgrade, posebno kad se upravlja s više zgrada (npr. stambeni fond grada), treba pažljivo isplanirati, radi optimalizacije ulaganja i optimalne raspodjele sredstava na najvažnije zahvate. Problem održavanja treba promatrati u kontekstu cjelokupnog procesa građenja, budući da zadovoljavanje potreba za građevinama podrazumijeva međusobnu povezanost građevinskih aktivnosti kao što su izgradnja novih zgrada, modernizacija i zamjena postojećih te održavanje [58]. Kako je već navedeno, održavanje uvijek treba uzimati u obzir već kod planiranja izgradnje neke građevine te računati s troškovima održavanja kada se na početku predlažu i biraju varijantna rješenja.

Za projekte javnih građevina karakteristično je što je investitor, odnosno vlasnik prisutan od početka do kraja projekta, odnosno od izbora projektne ideje, preko izrade projekta, izbora izvođača radova, izgradnje te do faze uporabe. Tijekom uporabnog vijeka građevine javlja se nekoliko skupina troškova, od kojih mnogi (kao i drugi troškovi uporabe) uvelike ovise o odlukama koje se donose prije početka gradnje [44].

Troškovi održavanja i uporabe građevina dio su troškova životnog ciklusa građevina, odnosno ukupnih životnih troškova građevina, što je definirano normom ISO 15686-5:2017 *Buildings and constructed assets - Service life planning - Part 5: Life-cycle costing*. Prema navedenoj normi, u troškove životnog ciklusa ubrajaju se indirektni troškovi i prihodi koji skupa s troškovima životnog ciklusa (izgradnja, uporaba, održavanje i uklanjanje) čine ukupne životne troškove građevina [59].

Istraživanje koje je proveo Zavod za ekonomsko planiranje pokazalo je da je za vijek trajanja građevine od 100 godina u investicijsko održavanje potrebno uložiti 155 % od vrijednosti početnog ulaganja tijekom 90 godina, dok je slično istraživanje provedeno u Švedskoj pokazalo da za vijek trajanja građevine od 80 godina treba uložiti također 155 % od vrijednosti ulaganja, tijekom 75 godina. Zaključak je da u prosjeku u građevinu treba uložiti 189 % od njezine investicijske vrijednosti, tj. skoro dva puta više nego za samu izgradnju [55], [60].

U troškove održavanja građevina ulaze troškovi potrebnog rada, materijala i ostali vezani troškovi koji se javljaju kod održavanja definirane razine služnosti neke građevine. Troškovi održavanja obuhvaćaju troškove korektivnog, preventivnog i reaktivnog održavanja cijele građevine ili njezinih dijelova. Operativni troškovi ili troškovi korištenja su troškovi uporabe i

gospodarenja nekom građevinom, a obuhvaćaju poreze, najam, kamate, troškove energije, čišćenja i ostalih potrebnih usluga ovisno o namjeni građevine te troškove svih potrebnih inspeksijskih pregleda koji su propisani određenim zakonskim propisima [59].

Ciljevi održavanja građevina su sljedeći:

- osiguranje sigurnosnih zahtjeva građevine i pripadajućih usluga
- osiguranje prikladnosti građevine za uporabu
- osiguranje ispunjenja zahtjeva građevine s obzirom na zakonske propise
- izvođenje neophodnih poslova održavanja radi očuvanja vrijednosti imovine i
- izvođenje neophodnih poslova održavanja radi očuvanja kvalitete građevine [59].

Održavanje građevina može se podijeliti na:

- preventivno održavanje koje može biti bazirano na stanju elemenata ili na vremenu i
- reaktivno održavanje koje se bazira na otkazivanju elemenata.


Preventivno održavanje obuhvaća zakonom propisane periodične preglede, zamjenu istrošenih materijala i elemenata te planirane periodične radove i popravke.

Reaktivno održavanje svodi se na popravke u sklopu hitnih intervencija, kao što su kvarovi na instalacijama, sustavu grijanja, puknuća, oštećenja krovišta i slično [44].

Tehničko upravljanje i održavanje građevina (i postrojenja) u širem smislu (a odnosi se najviše na građevinsko, strojarско i elektro održavanje) je skup tehničkih i administracijskih aktivnosti s namjerom da se građevina ili bilo koji njen dio zadrži ili vrati u stanje u kojem je sposoban vršiti svoju projektiranu namjenu uz što manje (optimalne) financijske izdatke [41].

Budući da faza uporabe građevine traje najduže, potrebno je nešto reći i o troškovima u toj fazi. U troškove ove etape upravljanja održavanja i uporabe građevine (*Facility Management phase*) ubrajaju se svi troškovi potrebni za uporabu, održavanje i logističku potporu građevine, tijekom cijelog njezina vijeka uporabe, i indirektni troškovi potrebni za upravljanje ovom etapom [27].

Na slici 2.5. prikazana je struktura troškova upravljanja, održavanja i uporabe građevine. Navedena struktura primjenjiva je i na problematiku održavanja kanalizacijskih sustava.



Slika 2.5. Troškovi upravljanja, održavanja i uporabe građevine [27]

Preventivno održavanje je ono u kojem se postupci održavanja provode prije nego što dođe do kvara ili otkaza tako da se kod takve vrste održavanja kvar ili otkaz sprječava ili se razdoblje između dva održavanja produžuje [61].

Zakonska regulativa koja obuhvaća pojmove održavanja građevine, propisuje postupak i način održavanja te novčane kazne u slučaju neodržavanja, je sljedeća:

- Zakon o gradnji (NN 153/13, 20/17, 39/19, 125/19)
- Pravilnik o održavanju građevina (NN 122/14, 98/19)
- Uredba o održavanju zgrada (NN 64/97).

Strogo formalno, članak 3. Zakona o gradnji (NN 153/13, 20/17, 39/19, 125/19) definira što se smatra pod pojmom održavanja građevina:

„Održavanje građevine je izvedba građevinskih i drugih radova na postojećoj građevini radi očuvanja temeljnih zahtjeva za građevinu tijekom njezina trajanja, kojima se ne mijenja usklađenost građevine s lokacijskim uvjetima u skladu s kojima je izgrađena“.

Nadalje članci 150., 151. i 152. Zakona o gradnji navode:

„Vlasnik građevine odgovoran je za njezino održavanje. Vlasnik građevine dužan je osigurati održavanje građevine tako da se tijekom njezina trajanja očuvaju temeljni zahtjevi za građevinu te unapređivati ispunjavanje temeljnih zahtjeva za građevinu, energetskih svojstava zgrada i nesmetanog pristupa i kretanja u građevini“ [57].

„U slučaju oštećenja građevine zbog kojeg postoji opasnost za život i zdravlje ljudi, okoliš, prirodu, druge građevine i stvari ili stabilnost tla na okolnom zemljištu, vlasnik građevine dužan je poduzeti hitne mjere za otklanjanje opasnosti i označiti građevinu opasnom do otklanjanja takvog oštećenja.“

„Održavanje građevine te poslove praćenja stanja građevine, povremene godišnje preglede građevine, izradu pregleda poslova za održavanje i unapređivanje ispunjavanja temeljnih zahtjeva za građevine i druge slične stručne poslove vlasnik građevine, odnosno osoba koja obavlja poslove upravljanja građevinama prema posebnom zakonu mora povjeriti osobama koje ispunjavaju uvjete za obavljanje tih poslova propisane posebnim zakonom“ [57].

„Redovito održavanje jest preventivno pregledavanje građevine odnosno njezinih dijelova i preventivno izvođenje radova kojima se sprječava gubitak svojstava građevine i njezine funkcionalnosti definirane namjenom u projektu građevine, kao i izvođenje radova na zamjeni, dopuni i/ili popuni dijelova građevine u razmacima i opsegu određenim projektom građevine ili zbog narušenog svojstva i/ili funkcionalnosti tih dijelova kojem uzrok nije kakav izvanredni događaj. Izvanredno održavanje jest izvođenje radova na zamjeni, dopuni i/ili popuni dijelova građevine nakon kakvog izvanrednog događaja nakon kojega građevina odnosno njezin dio više nije uporabljiv (npr. potres, požar, prirodno urušavanje tla, poplava, prekomjeran utjecaj vjetra, leda i snijega i sl.) odnosno ako je građevina ili njezin dio zbog nepropisnog održavanja ili kojeg drugog razloga dovedena u stanje u kojem više nije uporabljiva“ [62].

Članak 8. Pravilnika o održavanju građevina (NN 122/14, 98/19) navodi što se podrazumijeva pod pojmom održavanje građevina:

„Održavanje građevine podrazumijeva:

1. redovite preglede građevine odnosno njezinih dijelova, u razmacima i na način određen projektom građevine i pisanom izjavom izvođača o izvedenim radovima i o uvjetima održavanja građevine, ovim Pravilnikom i/ili posebnim propisom donesenim u skladu s odredbama Zakona o gradnji, a u slučaju ugrađene opreme, uređaja i instalacija i drugog i s planom servisiranja u rokovima propisanim u jamstvima proizvođača ugrađenih proizvoda,
2. izvanredne preglede građevine odnosno njezinih dijelova nakon kakvog izvanrednog događaja ili po inspekcijskom nadzoru,
3. izvođenje radova kojima se građevina odnosno njezin dio zadržava ili se vraća u tehničko i/ili funkcionalno stanje određeno projektom građevine odnosno propisima te aktima za građenje u skladu s kojima je građevina izgrađena,
4. vođenje i čuvanje dokumentacije o održavanju građevine: u kontinuitetu rednih brojeva navedeni i danom nastanka sastavljeni zapisnici s prilogima o redovitim i izvanrednim pregledima te izvedenim radovima u svrhu očuvanja projektiranih temeljnih zahtjeva za građevinu, funkcionalnosti i sigurnosti građevine u uporabi“ [62].

Uredbom o održavanju zgrada (NN 64/97) „uređuju se pitanja namjene sredstava zajedničke pričuve radi održavanja zgrada u suvlasništvu, vrste i način poduzimanja hitnih i nužnih popravaka na zgradama i pitanja u svezi dostavljanja podataka o stanovima“ [63].

Na kraju svega prethodno izloženog treba napraviti razliku između gospodarenja građevinama i održavanja građevina. Održavanje je sastavni dio gospodarenja građevinama te je uspješno gospodarenje uvijek bilo povezano s održavanjem. Ponekad je teško razlučiti može li se uopće gospodariti građevinama bez održavanja. Održavanje je tehnički dorečena i definirana disciplina. Iskustvo i praksa održavatelja od velike je koristi u uspostavi učinkovitog sustava gospodarenja građevinama.

Važno je napomenuti kako je literatura o troškovima životnog ciklusa većinom konceptualne prirode i postoji relativno malo dokaza o primjeni metodologije životnog ciklusa [64].

2.3. Dosadašnja istraživanja o mogućnostima optimizacije održavanja kanalizacijskog sustava

Kod optimizacije kanalizacijskog sustava jedna od važnih stavki je predviđanje životnog vijeka kanalizacije, odnosno njezinih sastavnih dijelova te planiranje preventivnih popravaka, zamjene cijevi ili njihove obnove.

Poznato je da kanalizacijskim cijevima (kolektorima) otječe otpadna voda koja sadrži različite agresivne tvari koje nagriza materijal od kojih su cijevi napravljene, a jedna od tvari je hidrogen sulfid koji nagriza beton. U radu [65] napravljena je umjetna neuronska mreža (UNM) temeljena na modeliranju stupnja korozije za predviđanje životnog vijeka betonskih cijevi u kanalizacijskoj mreži. UNM je treniran i validiran s eksperimentalno dobivenim podacima. Sam eksperiment, kojim su dobiveni podatci za izradu neuronske mreže, trajao je 4,5 godine te su korištene laboratorijske komore za koroziju. Verifikacija modela rađena je na stvarnim podacima dobivenim na području australske kanalizacijske mreže. Uporabom UNM-a dobivena su dosta dobra predviđanja korozije kanalizacijskih cijevi te je zaključeno da se UNM može koristiti za poboljšanje shvaćanja mehanizama korozije kanalizacijskih cijevi.

Rad [66] govori o automatskom otkrivanju površinskih oštećenja cijevi. Postupak snimanja kanalizacijskih cijevi, pregledavanja snimki te na kraju, najvažnijeg dijela, otkrivanja površinskih oštećenja cijevi, zahtijeva dosta vremena, veoma je naporan i skup. Budući da otkrivanje površinskih oštećenja rade ljudi, tako je veoma lagano pogriješiti u tom poslu. Automatizacija u tom postupku uključuje snimanje, digitalne videosnimke, obradu i analizu snimaka, zatim prepoznavanje uzoraka i klasifikaciju pomoću UNM-a. UNM je razvijen i treniran sa svrhom prepoznavanja oštećenja cijevi, a program koji je korišten za izradu UNM-a je *NeuroShell 2*. Nakon treniranja umjetne neuronske mreže uočeno je da je pogodna za otkrivanje oštećenja na betonskim i glinenim kanalizacijskim cijevima.

Sinha i Fieguth [67] koriste UNM kako bi otkrili oštećenja podzemnih cijevi. Oštećenja koja se prepoznaju su pukotine, rupe, slomljene spojnice cijevi, bočni priključci cijevi te ostalo. U ovom radu UNM se koristi kako bi se klasificirala i prepoznala navedena oštećenja. Kod samog treniranja UNM-a mora se obratiti pažnja da mreža ne bude pretrenirana, budući da se onda mogu pojaviti rezultati koji su lošiji (netočniji) nego prije treniranja mreže.

Radovi autora [68]–[70] bave se sličnom (čak se može reći istom) problematikom. Radovi obrađuju problematiku pogoršanja strukturnog stanja kanalizacijskih cijevi, i to samo onih

cijevi za oborinsku odvodnju. Sva tri rada odnose se na cijevi u Australiji. Snimanja su rađena pomoću CCTV-a (engl. *closed-circuit television* – snimanje kamerama, televizijska inspekcija) te se na osnovi tako dobivenih snimaka radila procjena stanja cijevi. U ovim radovima je predložen model temeljen na UNM-u koji bi procjenjivao stanje betonskih kanalizacijskih cijevi pomoću određenih zadanih podataka (ulaznih faktora ili karakteristika). Odabrane su betonske cijevi zbog toga što je promatrani kanalizacijski sustav u najvećoj mjeri sastavljen od njih. Program koji je rabljen za izradu UNM-a je MATLAB. Između devet ulaznih faktora, otkriveno je da su faktori starost cijevi i lokacija beznačajni, dok su veličina cijevi, nagib, broj drveća i klimatski uvjeti (engl. *Thornthwaite Moisture Index*, TMI) važni faktori kod modeliranja starenja cijevi. Hidrauličko stanje, vrsta tla i dubina mogu se smatrati kao višak i nisu potrebni [69]. U svim radovima je zaključeno da UNM može s dosta dobrom točnošću predvidjeti stanje cijevi. Usporedbom rezultata u sva tri rada vidljivo je da nisu isti svi faktori koji su kritični, odnosno koji su potrebni za procjenu točnog stanja cijevi.

Rad [71] obrađuje predviđanje strukturalnog stanja kanalizacije pomoću UNM-a.

Točno predviđanje performansi cjevovoda važno je za određivanje trajanja i upravljanje rizikom svake podzemne infrastrukture kao što su kanalizacijske cijevi. Varijable korištene za modeliranje UNM-a su duljina cijevi, veličina (promjer), vrsta materijala, starost kanalizacije, dubina, nagib i vrsta kanalizacije. Neuronska mreža rađena je u programu *BrainMaker*. Utvrđeno je da je procjenjivanje stanja cjevovoda pomoću UNM-a izvedivo te da točnost modela ovisi o veličini uzorka na kojem se radi [72].

Autori u radu [73] koriste UNM kako bi prepoznali različite vrste oštećenja u kanalizacijskim cjevima. Korišteni program je MATLAB. Uočeno je da je otkrivanje spojeva cijevi provedeno sa 100 %-tnom točnošću, a također su s dosta dobrom točnošću otkrivane pukotine i bočni priključci cijevi.

U radu [74] umjetna neuronska mreža se koristi kako bi se predvidio protok u kanalizaciji za vrijeme kišnog vremena u ovisnosti o intenzitetu kiše. Navedeno je važno jer se dimenzioniranje kanalizacijskih cijevi (određivanje potrebnih promjera cijevi) radi, između ostalog, i prema tim podacima. U tom je radu bilo dosta znati intenzitet kiše, dok podatci o fizičkim karakteristikama sliva nisu bili potrebni.

Ebtehaj i Bonakdari [75] koriste UNM kod predviđanja transporta sedimenta upotrebljavajući koncept samočišćenja kanalizacijskih sustava. Pojava sedimenta u cjevima uzrokovana je

promjenama tečenja. Predviđanje transporta i količine sedimenta važno je zbog toga što taloženje sedimenta uzrokuje smanjenje profila cijevi (smanjuje se protok), moguće je izlivanje sadržaja kanalizacije, povećava se korozija cijevi te pojava neugodnih mirisa što sve zahtijeva pojačano održavanje. Upotrebom UNM može se dosta dobro predvidjeti transport sedimenta (blizu mjerenjima provedenima na terenu). Također, pokazano je da UNM navedeno predviđa s puno većom točnošću nego razne do sada korištene empirijske jednadžbe.

Rad [76] bavi se predviđanjem troškova gradnje vodovodnih i kanalizacijskih sustava. UNM je rađen pomoću programa *NeuroShell 2*, verzija 4.0. Sve su procjene rađene na temelju osnovna četiri parametra: rad, materijal, oprema i drugi troškovi. Dobiveni model uključuje podatke kao što su prosječna mjesečna temperatura, zemljopisna lokacija projekta i uvjeti na terenu.

U radu [77] rađena je optimizacija kanalizacijskog sustava te je pokazano da su ostvarene uštede od 19,5 % ukupne vrijednosti investicije upotrebom genetskog algoritma.

U radu [78] je predložen model za planiranje optimalnog načina obnove kanalizacijskog sustava. Pomoću CCTV snimki, neuronskih mreža koje su se koristile za klasifikaciju oštećenja na snimkama i genetskih algoritama rabljenih za odlučivanje o optimalnom načinu obnove kanalizacijskog sustava, radilo se održavanje kanalizacije. Genetski algoritmi su, između ostaloga, korišteni za određivanje optimalne metode obnove i zamjenskog materijala. Na kraju je u geografskom informacijskom sustavu (GIS-u) izrađen plan obnove kanalizacijskog sustava te je sve pregledno prikazano.

Također i rad [79] govori o izradi optimizacijskog modela koji je korišten u svrhu pronalaženja odgovarajućeg načina obnove kanalizacijskih cijevi i vrste materijala kojim će se obnova raditi, a sve u ograničenom, unaprijed zadanom financijskom okviru, što je u stvarnosti uvijek slučaj. Kao rezultat korištenog optimizacijskog modela, ostvarena je ušteda na obnovi od oko 20 % kada se usporedi sa standardnim procjenama stručnjaka koje su uobičajeno u uporabi.

U radu [80] je rađeno nešto slično kao u prethodnom radu te je genetski algoritam korišten kako bi se pronašla isplativa rješenja obnove kanalizacijskog sustava. Autori rada su utvrdili da je zamjetan nedostatak literature koja obrađuje problematiku optimizacije upravljanja kanalizacijskom mrežom pomoću genetskih algoritama.

Rad [81] govori o višekriterijskom pristupu pregledu kanalizacijskih cijevi. Od kanalizacijskog sustava se očekuje da radi bez prekida, stoga je veoma važno njegovo održavanje. U radu je

pomoću višekriterijskog genetskog algoritma (MOGA) rađena višekriterijska optimizacija rizika od kvara cijevi, troškova pregleda te troškova popravaka. Navedeni pristup prikazan je na kanalizacijskom sustavu u Velikoj Britaniji.

Autor van Vuuren u svom se radu [82] bavi primjenom genetskog algoritma za određivanje optimalnog promjera cijevi. Poznato je da ako se nađe optimalni (manji) promjer, on će smanjiti kapitalne troškove, ali će operativni troškovi (troškovi crpki) narasti i s njima će porasti mogućnost puknuća cijevi zbog povećanih tlakova i povećanih brzina. Zbog toga je potrebno provesti optimizaciju promjera cijevi [82].

Afshar koristi genetski algoritam za određivanje optimalnog dizajna oborinske kanalizacijske mreže. Pokazano je da genetski algoritam može biti učinkovit za rješavanje stvarnih problema velikih razmjera – kanalizacijskih sustava velikih obuhvata gdje druge metode često nisu bile od koristi [83].

Ward i Savić [84] koriste genetski algoritam u svrhu višekriterijske optimizacije modela za obnovu kanalizacije uzimajući u obzir rizik od kvara. Podatci su dobiveni CCTV metodom, a klasifikacija (odnosno optimizacija) je rađena prema metodi MSCC4 (od engl. *Method of Sewer Condition Classification* – metoda klasifikacije stanja kanalizacije) kako bi se pronašlo optimalno rješenje za obnovu kanalizacijskog sustava uzimajući u obzir tri suprotstavljena cilja:

1. maksimalizirati poboljšanje strukturalnog stanja
2. smanjiti građevinske troškove i
3. minimizirati kvar kritične imovine.

Pokazano je da je teško naći globalni optimum rješenja, ali je pomoću razvijenog višekriterijskog modela moguće biti što bliže optimalnom rješenju, koje bi inače bilo zanemareno [84].

U radu [85] razvijen je ekspertni sustav čija namjena je poboljšanje aktivnosti održavanja kanalizacijskog sustava te otkrivanje potreba za popravcima. Navedeni ekspertni sustav nazvan je APOGEE (skraćeno od franc. *Analyses et Programmation Optimise pour la Gestion, L'Entretien et L'Exploitation du Reseaux d'Assainissement*, engl. *Analysis and Optimal Programming for the Management, Maintenance and Use of a Sewer Network*, hrv. analiza i optimalno programiranje upravljanjem, održavanjem i upotrebom kanalizacijske mreže), a napisan je u PROLOG-u. APOGEE ima dvije osnovne funkcije: dijagnozu stanja

kanalizacijske mreže, uključujući rizik od propadanja te odlučivanje o načinu, programu popravaka i rasporeda pregleda kanalizacijskog sustava.

U radu [86] razvijen je ekspertni sustav (ES) kako bi pomogao kod odlučivanja koji su primarni ciljevi kod obnove kanalizacijske mreže. Doprinos rada je taj što je razvijen sustav vrednovanja prioriteta za obnovu kanalizacije. Za svaki dio kanalizacijske mreže izračunat je indeks svojstava, posebno za strukturna, hidraulička i globalna svojstva, uzimajući u obzir stanje unutar kanalizacijskih cijevi, hidrauličko ponašanje cijevi i okruženje te cijevi. Cijevi s istim hidrauličkim i strukturalnim svojstvima su klasificirane različito kada su imale različit stupanj osjetljivosti s obzirom na položaj gdje su postavljene. Ova klasifikacija, koja je preciznija, ima određene prednosti kod odlučivanja o odabiru cijevi koje će se obnoviti. Također, velika prednost ovog načina vrednovanja prioriteta je ta što se u obzir uzima i proučava njihovo međusobno djelovanje koje je opasnije za stanje cijevi, a ne uzima se samo u obzir više različitih parametara.

Autori Hahn, Palmer i Merrill [87] razvili su ES koji služi za određivanje primarnih ciljeva pregleda kanalizacije. Također, ES određuje potencijalni rizik i moguće posljedice, predlaže prikladnu metodu pregleda i upozorava korisnika kada je potrebno više dodatnih informacija kako bi se moglo napraviti bolje odlučivanje. Određivanje prioriteta pregleda kanalizacijskih elemenata smanjuje potreban broj inspekcija, a kao rezultat toga smanjuje potrebu za hitnim popravcima i smanjuje troškove.

U radu [88] prethodna tri autora uz još jednog – Lukasa – razvili su ES i pripadajuću bazu podataka za pomoć pri odlučivanju kod pregleda kanalizacije. ES je rađen pomoću Bayesove mreže koja dopušta nesigurnost stručnjaka kroz cijeli proces odlučivanja. Baza podataka i ES su ocjenjivani s nekoliko studija slučaja te je pokazano da su učinkoviti kod oponašanja znanja koje posjeduje stručnjak. Baza ekspertnog sustava nazvanog SCRAPS (od engl. *Sewer Cataloging, Retrieval and Prioritization System*, hrv. sustav za katalogizaciju kanalizacije, davanje podataka i prioritizaciju) je Bayesova mreža. Kako kanalizacija stari, pogoršava se njezino stanje, tako su potrebne sve skuplje inspekcije te je važno napraviti raspored inspekcija s obzirom na dio kanalizacijskog sustava kod kojeg postoji najveći rizik. Baza podataka navedenog sustava je napravljena i kalibrirana s više od 100 slučajeva kanalizacijskih cjevovoda. Kod ocjenjivanja SCRAPS je pokazao slično prosuđivanje kao i kada bi ljudski stručnjak odlučivao o kvaru, ali je ipak bio nešto konzervativniji nego čovjek [88].

Ana i Bauwens [89] napravili se pregled alata koji služe kao potpora odlučivanju kod upravljanja kanalizacijskim sustavom. Između dosta navedenih alata, govori se i o već prije spomenutom APOGEE sustavu koji je razvijen s ciljem optimizacije planiranja i obnove kanalizacijske mreže na godišnjoj razini. Sustav se sastoji od tri osnovne komponente: baze podataka, ekspertnog sustava i modula za planiranje intervencija i popravaka kanalizacijske mreže. Pomoću navedenog sustava olakšava se održavanje kanalizacijskog sustava.

Rad [90] također koristi ekspertni sustav SCRAPS kako bi predvidio kritične dijelove kanalizacijskog sustava. U bazu podataka SCRAPS-a uneseni su podatci o promjerima cijevi, učestalosti plavljenja, prodoru korijenja, taloženju, koroziji, starosti cijevi, razini podzemne vode i dubini postavljanja cijevi. Pokazano je da uporaba SCRAPS-a uz korištenje hidrauličkog modeliranja može biti od velike koristi kod vrednovanja podataka o kanalizacijskom sustavu i izradi plana potrebnih inspekcija u svrhu očuvanja zahtjevanog nivoa služnosti.

Kod planiranja pregleda i inspekcija kanalizacijskih cijevi koristi se stablo odlučivanja. Predviđanje stanja cijevi je jako težak zadatak, a korištenjem stabla odlučivanja odabir kanalizacijskih cijevi za pregled i inspekciju uvelike se olakšava. Koncept stabla odlučivanja je općenit te je dobiveni model razumljiv i onima koji nisu upoznati s metodama rudarenja podataka i statističkim metodama za koje često nedostaju znanja kada se koriste statističke metode ili metode strojnog učenja. Karakteristike koje su korištene za rudarenje podataka su: materijal cijevi, starost, vrsta (glavni ili priključni cjevovod), promjer, duljina, nagib, dubina dna cijevi, dubina, vrsta pokrova na terenu iznad cijevi, puknuća vodovodnih cijevi unutar 3 m od cijevi, stanje cijevi [91]. U radu je zaključeno da su stabla odlučivanja jednostavna i učinkovita metoda koja daje dobar uvid kako određeni parametri cijevi utječu na strukturalno stanje pojedinačnih cijevi. Trenirani klasifikator stabla odlučivanja ukazuje da je starost cijevi važna za određivanje strukturalnog stanja sanitarne kanalizacije. Također, stablo odlučivanja pokazuje na postojanje povećane mogućnosti kvara cijevi u slučaju kada je kanalizacijska cijev postavljena pliće, kada je cijev veće duljine, manjeg promjera te u slučaju kada se u blizini promatrane cijevi dogodilo puknuće vodovodne cijevi [91].

Autori Ana i Bauwens [92] modelirali su proces starenja cijevi gradske oborinske odvodnje pomoću Markovljevog lanca. Markovljev model je snažan algoritam za modeliranje starenja cijevi, budući da je njegov koncept jednostavan, a njegova struktura dopušta složene događaje kao što je starenje cijevi. Prezentirali su najučestalije statističke modele za modeliranje strukturalnog propadanja gradskih odvodnih cijevi. Autori su zaključili da kako bi se razvio

pouzdan model propadanja kanalizacijskih cijevi, potrebno je provođenje rutinskih inspekcija i čuvanje podataka o provedenim inspekcijama i pregledima. Unatoč dostupnosti različitih modela propadanja cijevi, sve je još u počecima, a šire prihvaćanje modela ovisi o dostupnosti dokaza o pouzdanosti prognoza [92].

U radu [93] Markovljev proces koristi se kod obnove kanalizacije. Razumijevanje mehanizama starenja kanalizacije omogućuje stručnjacima koji su zaduženi za održavanje i kontrolu kanalizacije, razvijanje modela koji dozvoljava procjenu hoće li se dogoditi kvar kanalizacijskog sustava ili neće. Upotreba modela starenja zajedno s analizom troškova životnog ciklusa (engl. *Life cycle cost analysis*, LCCA) omogućuje smanjenje troškova građenja, upravljanja i održavanja.

Marzouk i Omar [94] su napravili algoritam za višekriterijsku optimizaciju obnove kanalizacijske mreže, a Markovljev lanac je osnova koju model koristi za predviđanje starenja kanalizacijske mreže. Markovljevi modeli daju pouzdan mehanizam za razvoj modela predviđanja. Modul za predviđanje stanja kanalizacije predviđa stanje kanalizacije za idućih 50 godina.

U radu [95] napravljen je Markovljev model za modeliranje starenja cijevi oborinske odvodnje. Model je kalibriran pomoću Bayesove metode i baze podataka o strukturi grada Newcastle (Australija). Markovljeve prijelazne vjerojatnosti su procijenjene uz pomoć *Metropolis-Hastingsovog* algoritma. Pokazano je kako je Markovljev model prikladan za modeliranje starenja cijevi te je utvrđeno da različite karakteristike cijevi: promjer cijevi, materijal, vrsta tla i stupanj izloženosti utječu na proces starenja.

Baik, Abraham i Gipson [96] koriste Markovljev lanac u modelu starenja koji je razvijen pomoću podataka o kanalizaciji u grada San Diegu.

U radu [97] govori se o analizi troškova životnog ciklusa upravljanja podzemnom infrastrukturom temeljenom na optimalnom održavanju i obnovi. Markovljev lanac i pripadajući model starenja koristi se kako bi se pomoglo objasniti starenje cijevi kroz godine. U radu je prikazan okvir za donošenje odluka kod upravljanja sanitarnom kanalizacijom koji mogu koristiti upravitelji održavanja građevina. Navedeni okvir služi za određivanje optimalnog plana održavanja i obnove koji minimalizira troškove životnog ciklusa. Rezultati dobiveni pomoću modela starenja služili su za razvoj optimalne strategije održavanja i obnove te su buduća stanja sustava predviđana, a kada je određena optimalna metoda održavanja i

obnove, moguće je izračunati potreban proračun za procijenjene radove. Modeli Markovljevih lanaca su već prije uspješno korišteni kod predviđanja starenja različite infrastrukture. Dobivena krivulja starenja kanalizacije nije linearna, nego eksponencijalna, što govori da kanalizacija ne stari jednako u vremenu [97].

Rezultati dobiveni iz modela starenja korišteni su u daljnjem razvijanju optimalne strategije održavanja i obnove koristeći analizu životnih troškova. Kada je pronađena optimalna metoda održavanja i obnove, procijenjen je potrebni budžet za izvođenje radova za različita razdoblja. Primjena navedenog modela pokazuje da je moguće pronaći problematična područja kanalizacijske mreže i popraviti ih te na taj način spriječiti velike troškove koje se javljaju kod ozbiljnih kvarova, a onda i popravaka [97].

U radu [98] razvijen je optimizacijski model za upravljanje kanalizacijskom mrežom. Promatrana kanalizacijska mreža podijeljena je na manje dijelove te je napravljen pregled ulaskom čovjeka u cijev (promjer kanalizacije je 150 cm i širi) te CCTV metodom. Markovljev model pokazao se pouzdanim za razvijanje modela predviđanja. Model je koristan za menadžere koji upravljaju održavanjem kada su suočeni s optimizacijskom problemom, a to je, može se reći, uvijek – ograničeni budžet, a potrebno je izvesti određene radove.


Baik, Jeong i Abraham [99] razvili su modele starenja u upravljanju kanalizacijskim sustavima na osnovi Markovljevog lanca. Utvrđeno je da su neki od potrebnih podataka za uspješnije i točnije predviđanje starenja kanalizacijskih sustava dubina postavljanja cijevi, vrsta (stanje) tla, razina podzemne vode, učestalost prelijevanja kanalizacije.

2.4. Dosadašnja istraživanja o predviđanju troškova održavanja građevina

Predviđanje građevinskih troškova u svrhu smanjenja rizika je nezamjenjiv korak kod odlučivanja. Također, predviđanje troškova je važan proces za svaki posao budući da to prethodi određivanju budžeta i raspodjelu resursa u životnom ciklusu projekta. Zapravo, teško je dobiti ulazne podatke za proces procjene troškova, dok je opseg posla jedva poznat te bi mogao dovesti do loših i grubih procjena. Štoviše, što je projekt bolje definiran i opisan, to je lakše napraviti procjenu troškova projekta koja je preciznija. Međutim, mora se uzeti u obzir da prevelikom razradom projekta proces kontrole troškova postaje teži ako se projekt temelji na netočnim procjenama troškova. Također, podcjenjivanje ili precjenjivanje procjene troškova

dovest će do devijacija u budućnosti, odnosno razlikovat će se planirani i realizirani budžet [100]. Jedan od većih problema u održavanju je taj što nema normi za određivanje prikladnog budžeta za aktivnosti uporabe i održavanja te su jedine norme povijesni podaci. Jednostavno se desecima godina prije budžet dodjeljivao po proceduri *ad hoc* te se svake iduće godine samo povećavao za određeni postotak [101].

Kako bi se moglo na početku projektiranja utjecati na troškove održavanja, važno je već na početku voditi računa o troškovima održavanja. Stoga, mogućnost utjecaja na troškove na početku je najveća, kako projekt odmiče (faza građenja) utjecaj je manji, dok je u fazi uporabe građevina jako malo moguće utjecati na troškove budući da je građevina već izgrađena te je potrebno puno financijskih resursa za ispravljanje nečega što se moglo ispraviti ili predvidjeti na početku [102].



Slika 2.6. Mogućnost utjecaja na troškove projekta (prilagođeno prema: [102])

Na slici 2.6. prikazan je porast troškova kako projekt napreduje te mogućnost utjecaja na troškova s napredovanjem projekta. Tako je i kod kanalizacijskih sustava već na početku važno voditi računa o svim karakteristikama sustava koji se projektira, odnosno koji se odabere između različitih varijantnih rješenja. Kod samog projektiranja kanalizacijskog sustava na početku se određuju promjeri i vrsta cijevi te pažljivim izračunom, ali i odabirom moguće je utjecati na troškove održavanja kanalizacijskog sustava jer je npr. poznato i logički shvatljivo da su (pre)mali promjeri cijevi skloni većoj učestalosti začepljenja te treba uzeti u obzir ograničenja minimalnih promjera cijevi za pojedine vrste kanalizacije. Također, o odabiru vrste cijevi, između ostaloga, ovisi koliko često je potrebno čistiti cijevi (koliko se talože nečistoće), koja je čvrstoća cijevi i otpornost, trajnost itd. Prema tome, na početku uz male troškove izmjena tih karakteristika kanalizacijskog sustava moguće je napraviti velik utjecaj na kumulativne troškove projekta, a samim time i na troškove održavanja jer oni ulaze u ukupne životne troškove.

Mogućnost predviđanja i procjene troškova, bilo građenja, bilo uporabe i/ili održavanja, veoma je važno iz različitih razloga (investitora zanima koliko stoji građenje neke građevine, korisnike zanimaju troškovi uporabe i održavanja). Kako bi se moglo predvidjeti troškove održavanja, potrebno je prikupiti podatke o karakteristikama građevina i povijesnim troškovima održavanja [103]. Povijesni zapisi o troškovima održavanja i trendovima kretanja troškova su najvrjedniji podaci kada se planira budžet za održavanje [104]. Međutim, procjene troškova u budućnosti su samo – procjene. Za vrijeme planiranog životnog vijeka građevine donosit će se puno odluka koje je nemoguće unaprijed znati, a koje utječu na troškove izgradnje i održavanja [105]. Ali, bez obzira na to, predviđanje i procjena troškova je korisno i potrebno, oduvijek je bilo u interesu brojnih istraživanja i uvijek će biti budući da mogućnost pravovremenog predviđanja troškova održavanja otvara mogućnosti pripreme proračuna za troškove održavanja. Kada je određeni novčani iznos predviđen i pripremljen za održavanje građevina, onda se to održavanje može pravilno provoditi, tako spriječiti propadanje imovine te svim korisnicima omogućiti ugodan boravak i uporabu predmetne imovine.

Povijesni podatci o troškovima projekata mogu se i već su se koristili u različitim istraživanjima kako bi se razvio model praćenja i predviđanja svojstava, ali i različitih vrsta troškova [106], [107]. Troškovi uporabe i održavanja igraju veliku ulogu u ukupnim troškovima vlasnika građevine za vrijeme uporabnog vijeka iste. Točno predviđanje tih

troškova može pomoći upravitelju i vlasniku građevine kod donošenja odluka i određivanja potrebnog budžeta za održavanje.

U radu autora [108] napravljen je model za predviđanje troškova održavanja i troškova popravaka uredskih zgrada. Nadalje, u radu [109] napravljen je regresijski model za predviđanje održavanja te proučen utjecaj karakteristika na održavanje poslovnih zgrada u Maleziji. Istraživanje je rađeno pomoću pregleda literature, upitnika (za koje se pokazalo da su najbolji način prikupljanja podataka) i polustrukturiranog intervjua. Napravili su dva regresijska modela za predviđanje u programu SPSS (skraćenica od engl. *Statistical Package for the Social Sciences*). U radu je zaključeno da se regresijski model može koristiti u praksi [109].

Autori Krstić i Marenjak [59] u svom su radu istraživali mogućnost prikupljanja povijesnih podataka o troškovima održavanja i uporabe građevina Sveučilišta Josipa Jurja Strossmayera u Osijeku, a za potrebe tog istraživanja sastavljene su ankete i upitnici. Pomoću anketa i upitnika prikupljeni su podatci o troškovima održavanja, uporabe i podatci o karakteristikama građevina.

Prethodna dva autora također su opisali razvoj i validaciju modela prosječnih godišnjih troškova održavanja i uporabe sveučilišnih građevina koje imaju slične karakteristike za područje Osijeka. Pokazano je da je moguće predvidjeti troškove održavanja i uporabe građevina slične namjene na godišnjoj bazi. Uz potrebnu malu količinu ulaznih podataka, također je omogućen uvid u statistički značajne varijable potrebne za predviđanje troškova održavanja i uporabe primjenom predloženog modela predviđanja troškova održavanja i uporabe. Predloženi model omogućuje procjenu troškova održavanja i uporabe i to već u fazi planiranja projekta [110].

Model za predviđanje troškova održavanja osnovnih škola izradili su autori Lee i Jeon. Razdoblje u kojem su proučavali troškove je 30 godina, a izrada modela rađena je regresijom [111].

Boussabaine i Kirkham [112] napravili su model za predviđanje troškova održavanja sportskih centara u Ujedinjenom Kraljevstvu. U analizi su otkrili da su varijable koje utječu na troškove održavanja sportskih centara površina poda, broj korisnika i veličina bazena.

Razvojem modela procjene troškova popravaka i održavanja za škole bavili su se autori Kim i sur. u radu [113], a model je izrađen regresijom. Model za predviđanje troškova održavanja

povijesnih građevina napravili su Mahmoud i sur., a točnost regresijskog modela je bila 93 % [114].

Autor Nipp [115] u svom je doktorskom radu proveo istraživanje na 34 zgrade Sveučilišta Tennessee Martin u Martinu, Tennessee, SAD. Te zgrade predstavljaju sveučilišni kampus. Izrađen regresijski model temeljen je na povijesnim podacima o troškovima za razdoblje od deset godina. Također, naglašava važnost dostupnosti povijesnih podataka o održavanju te ističe da ni jedna jednadžba za procjenu troškova ne jamči 100-postotnu sigurnost kod izračuna i planiranja budžeta, ali može biti od velike pomoći.

Autorica Tijanić Štok [116] je provela istraživanje o upravljanju javnim obrazovnim ustanovama s područja Primorsko-goranske županije. Za osnovne i srednje škole razvijena su četiri matematička modela za procjenu troškova održavanja temeljena na regresijskoj analizi te je zaključeno kada bi se navedeni model implementirao u rad škola, može se očekivati poboljšanje trenutne prakse procesa upravljanja održavanjem.

Prethodni radovi pokazuju da je za građevine poput škola, fakulteta, ureda i sportskih centara moguće izraditi model za predviđanje i procjenu troškova održavanja.

Drugom skupinom građevina, u ovom slučaju mostova, bave se sljedeća dva rada. Bouabaz i Horner istraživali su međusoban odnos i utjecaj troškova održavanja i površine ploče mosta, a izradili su model temeljen na regresiji. Model je služio za predviđanje termina održavanja mostova i procjenu tih troškova održavanja [117]. Shi i sur. [118] napravili su regresijski model za procjenu troškova održavanja armirano-betonskih grednih mostova u provinciji Shaanxi u Kini.

Osim regresijskih modela procjene troškova, za izradu modela koriste se umjetne neuronske mreže. U radovima su autori Li i Guo istraživali troškove održavanja za četiri sveučilišne zgrade. Za izradu modela koristili su jednostavnu linearnu regresiju, višestruku regresiju i umjetnu neuronsku mrežu, a kao najbolji model pokazao se onaj izrađen pomoću umjetne neuronske mreže [119], [120]. Troškovima održavanja mostova bavili su se autori Bouabaz i Hamami [121]. Model je napravljen pomoću umjetne neuronske mreže, a postignuta je točnost od 96 %. Asadi i sur. napravili su model temeljen na umjetnoj neuronskoj mreži za predviđanje cjeloživotnih troškova mostova. Proučavali su troškove za 14 mostova u Chicagu, SAD [122]. U radu autorice Gudac Hodanić [123], razvijeni su modeli za procjenu troškova uporabe i troškova životnog ciklusa pontona i sidrenog sustava marine, izrađeni algoritmima strojnog

učenja: slučajnim šumama, neuronskim mrežama, potpornim vektorima i podizanjem gradijenta. Zaključeno je kako su razvijeni modeli primjenjivi i omogućavaju povećanje razine kvalitete odlučivanja kod upravljanja marinama.

Sažeti prikaz istraživanja o razvoju modela za predviđanje i procjenu troškova održavanja građevina dan je u tablici 2.1., navedena je vrsta građevine, način na koji je izrađen model te autori i godina izrade modela.

Tablica 2.1. Sažeti kronološki prikaz istraživanja o modelima predviđanja i procjene troškova održavanja različitih vrsta građevina

Vrsta građevine	Metoda izrade modela	Autori i godina
mostovi	regresija	Bouabaz i Horner, 1990. [117]
sportski centri	višestruka linearna regresija	Boussabaine i Kirkham, 2004. [112]
uredske zgrade	AHP metoda, regresija	Liu, 2006. [108]
sveučilišne građevine – fakulteti	višestruka linearna regresija	Krstić, 2011. [103]
sveučilišne građevine	višestruka linearna regresija	Krstić i Marenjak, 2012. [59]
poslovne zgrade	višestruka linearna regresija	Shah Ali i sur., 2013. [109]
povijesne zgrade	višestruka linearna regresija	Mahmoud i sur., 2015. [114]
sveučilišne građevine	višestruka linearna regresija	Krstić i Marenjak, 2017. [110]
osnovne škole	regresija	Lee i Jeon, 2017. [111]
zgrade sveučilišta – sveučilišni kampus	regresija	Nipp, 2017. [115]
škole	višestruka linearna regresija	Kim i sur., 2018. [113]
mostovi	regresija	Shi i sur., 2019. [118]
osnovne i srednje škole	regresija	Tijanić Štok, 2021. [116]
mostovi	umjetna neuronska mreža	Bouabaz i Hamami, 2008. [121]
mostovi	umjetna neuronska mreža	Asadi i sur., 2011. [122]
sveučilišne zgrade	jednostavna linearna regresija, višestruka regresija, neuronska mreža	Li i Guo, 2012. [119], [120]
pontoni i sidreni sustavi marine	algoritmi strojnog učenja: slučajne šume, neuronske mreže, potporni vektori, podizanje gradijenta	Gudac Hodanić, 2020. [123]

Kako se vidi iz prethodno analiziranih radova tablice 2.1., za dosta različitih vrsta građevina moguće je napraviti model za procjenu/predviđanje troškova održavanja. Međutim, za kanalizacijski sustav nije pronađen ni jedan rad gdje je izrađen model za procjenu troškova održavanja kanalizacijskog sustava. Kako je kanalizacijski sustav infrastrukturni sustav, komunalna vodna građevina, odnosno usluga javne odvodnje je vodna usluga koja je od općeg interesa, tako je važnost ovog rada još veća jer istražuje karakteristike kanalizacijskih sustava koje najviše utječu na troškove održavanja istih. Javnu odvodnju treba obavljati učinkovito i ekonomično [21] te je razvoj modela za procjenu troškova održavanja kanalizacijskog sustava važan doprinos pravilnijem, učinkovitijem, ekonomičnijem, ažurnijem održavanju kanalizacijskih sustava. Doprinos rada očituje se u spomenutom razvoju modela procjene troškova održavanja te razvoju strukture troškova održavanja koju je relativno lagano voditi, a koja omogućuje praćenje troškova na godišnjoj razini. Tada, ako se troškovi pravilno vode na godišnjoj razini, bit će moguće izraditi još točnije modele procjene troškove održavanja te će i poduzeća koja upravljaju kanalizacijskim sustavima uvidjeti koristi koje se ostvaruju praćenjem troškova i korištenjem modela za procjenu troškova održavanja.

3. KANALIZACIJSKI SUSTAVI

3.1. Povijest kanalizacijskih sustava

Kako se u radu obrađuje povećanje učinkovitosti održavanja kanalizacijskih sustava, u ovom dijelu rada daje se kratki dio o razvoju kanalizacijskih sustava kroz povijest. Također, dan je razlog izgradnje kanalizacijskih sustava i kako se shvatilo da kanalizacijski sustavi imaju veliku ulogu u razvoju čovječanstva i održavanju javnog zdravlja.

Puno je pisano o povijesti vodoopskrbnih sustava, dok je o kanalizacijskim sustavima zamjetan znatan nedostatak informacija, pogotovo u usporedbi s vodoopskrbnim sustavima. To je iznenađujuće budući da nedostatak sanitarnih uvjeta i kanalizacijskog sustava utječe na razvoj ljudskog društva u istoj ili čak u većoj mjeri nego nedostatak čiste vode [124]. Stoljećima se važnosti upravljanja otpadom nije pridavala pažnja te je u mnogim kulturama otpadna voda bila ispuštana na ulice ili unutar gradova tako ugrožavajući zdravlje stanovništva nekog grada. Navedeno se vidi po brojnim epidemijama koje su se pojavile u Europi u 19. stoljeću [125]. Da nije bilo epidemija zaraznih bolesti poput tifusa, kolere, kuge i drugih, vjerojatno svijest u Europi o potrebi pravilne odvodnje otpadnih voda i kanalizacijskim sustavima ne bi niti bila osviještena te se kanalizacijski sustavi ne bi gradili u tolikoj mjeri.

Već prije je primijećeno da ulaganje u sanitarnu infrastrukturu i njezin razvoj ima značajan utjecaj na smanjenje mortaliteta stanovništva [126]–[128] što su autori [127], [128] u radovima istražili i utvrdili. Područje koje su proučavali i za koje je rađena analiza je Engleska, Wales, Švicarska, Finska i Švedska. Autori istraživanja [127] bave se problematikom i istraživanjem utjecaja poboljšanja sanitarne infrastrukture na smrtnost u urbanim sredinama. Njihov poseban fokus je proučavanje poboljšanja opskrbe vodom i razvoja učinkovitih kanalizacijskih sustava. Vjerojatno su ta poboljšanja najviše utjecala na zdravlje smanjujući izloženost bolestima koje se prenose vodom i hranom [127]. Ova su istraživanja rađena za razdoblje od kraja 18. i za početak 19. stoljeća pa se može reći da je to novije razdoblje ako se usporedi s vremenom prije naše ere. Gledajući prethodno navedeno, čini se malo nevjerojatno da su stare civilizacije prije naše ere znale da su sanitarni uvjeti jako važni te su vodili brigu o sanitarnim uvjetima. Različite studije potvrdile su da dobri sanitarni uvjeti u nekom gradu imaju velik utjecaj na javno zdravlje ljudi [129]. Najveće smanjenje smrtnosti od zaraznih bolesti koje se prenose vodom bilo je zbog uspostavljanja poboljšanih sanitarnih uvjeta [130].

Relativno je teško točno definirati i sa sigurnošću reći gdje se odvođenje otpadnih voda najprije počelo koristiti, ali je sigurno da je to bilo kod starih civilizacija na Bliskom istoku, sjevernoj Africi te Srednjem i Dalekom istoku [131]. Najstarija pronađena cijev izrađena je od pečene gline i datira iz 4. st. prije naše ere, a osim nje pronađeni su još i koljena i T-dijelovi [132]. Potrebu za odvodnjom onečišćene vode iz naselja uočili su još prije puno vremena najstariji narodi kao što su Egipćani, Babilonci, Feničani i drugi. Ostatci kanalizacije postoje u više grčkih gradova kao što su Atena, Knosos i drugi [133]. U ruševinama Babilona pronađeni su ostaci fekalnih kanala te su Babilonci bili najpoznatiji po izradi cijevi koje su bile uglavnom od pečene gline, ali i bakra ili olova [132]. U Jeruzalemu su nečistu vodu odvodili kanalima u bazene za taloženje te je poslije mulj korišten kao gnojivo što je jedan od najstarijih primjera pročišćavanja otpadnih voda [134].

Odvodnja na ulicama poznata je još u vrijeme u mezopotamskog carstva u Iraku od oko 4000. do 2500. godine prije naše ere. Međutim, dobro organizirana kanalizacija po prvi puta u povijesti čovječanstva bila je kanalizacija minojske i harapinske civilizacije s Krete [135]. Najpoznatija kanalizacija starog vijeka bila je ona u Rimu. Ona je poznata kao „*Cloaca maxima*“ koja je bila visine 5 m, širine 4 m i 738 m duljine u koju su se ulijevali manji kanali na koje su bili spojeni kućni kanali. Također su postojali i javni zahodi [134]. *Cloaca Maxima* sagrađena je u vrijeme cara *Tarquinia Pricsa* (6. stoljeće prije naše ere), a još i danas služi jednom dijelu Rima odvođeci otpadne i oborinske vode u Tiber. Građena je iz eruptivnog kamena [126]. Postoji velika vjerojatnost da je *Cloaca maxima* sagrađena po koritu nekog vodotoka čija je prvotna namjena bila odvodnja i isušivanje močvarnih površina. Kasnije mu je funkcija proširena na odvodnju otpadnih voda [131]. Gradovi Rimskog Carstva poznavali su kanalizacijski sustav i odvodnju otpadnih voda te su pridavali veliku važnost tome [126] te se da zaključiti da su antički Rimljani vodili računa o vodi i kanalizaciji [136].

U današnje vrijeme kanalizacijski sustavi su podzemne građevine te su tako dobro integrirani u infrastrukturu da ih nismo ni svjesni [132]. Međutim, nije oduvijek kanalizacija bila podzemna građevina. Nekada je kanalizacija bila na ulici, kao što je bio primjer u Parizu, tada pod imenom *Lutecia* koja je osnovana oko 3. stoljeća prije naše ere. Međutim, taj se koncept napustio te kanalizacija ide ispod ulice – postaje podzemna građevina [137]. Kanalizaciju koju svi poznajemo u današnjem obliku počinje se graditi u velikim gradovima u Europi krajem 19. stoljeća. Gradnja je bila potaknuta velikim epidemijama zaraznih bolesti [132] kao što su kuga i kolera. Do sustavne gradnje kanalizacijskih sustava dolazi početkom 19. stoljeća i to u Velikoj

Britaniji, Francuskoj, Njemačkoj te nakon toga u ostalim europskim zemljama. Krajem 19. stoljeća gotovo svi veći europski gradovi imali su neki osnovni kostur kanalizacijskog sustava. Prvi veći kanalizacijski sustav u Europi je dovršen 1842. godine u Hamburgu [131]. Također, u 19. stoljeću pri gradnji gravitacijskih kanalizacijskih sustava koji se i danas primjenjuju počinju se koristiti razni građevinski materijali, te se vremenom razvijaju i zakonski propisi koji potiču izgradnju kanalizacijskih sustava [4].

U Hrvatskoj se može spomenuti grad Dubrovnik koji je u 13. stoljeću imao septičke jame i odvodne kanale sa svrhom suzbijanja epidemija kuge i kolere. U Dubrovačkom statutu se određuju parametri za izgradnju septičkih jama i kanala za odvod nečistoća. Istovremeno s rješavanjem problema odvođenja otpadnih voda, rješava se i problem odvođenja oborinskih voda u Dubrovniku [138]. Na području Istre, Pula je prvi grad koji je dobio suvremeni odvodni sustav [131]. U Splitu, Dioklecijanova palača imala je razvijen sustav kanalizacije [139]. U Zagrebu je na temelju iskopina utvrđeno da je još u vrijeme Rimljana naselje Andautonija imalo vodovod i odvodnju. Najstarija kanalizacija nađena je prilikom izgradnje tržnice na Dolcu u ostatcima samostana cistercita [126].

Zbog širenja grada Osijeka koji je kanalizacijske kanale imao riješene tako da su oni bili nadzemni te su bili izvor neugodnih mirisa i moguće zaraze, gradsko poglavarstvo odlučilo je izgraditi glavne sabirne kanale u Gornjem, Donjem i Novom gradu, u smjeru jug-sjever kojima bi najkraćim putem otjecale otpadne vode u rijeku Dravu. Nadalje, nakon izgradnje nekoliko glavnih kanalizacijskih kanala raspravljalo se o ulaganju grada u izgradnju cjelokupne gradske kanalizacije koja se i počela graditi, ali je prekinuta izbijanjem Prvog svjetskog rata. Tvrdća, dio grada u Osijeku, već je od 1779. godine imala kanalizaciju [140].

3.2. Kanalizacijski sustav i vrste kanalizacijskih sustava

Kanalizacijski sustav koristi se kod usluga javne odvodnje, a definicija javne odvodnje dana je u Zakonu o vodnim uslugama. Prema Zakonu o vodnim uslugama (NN 66/19) javna odvodnja je „djelatnost skupljanja komunalnih otpadnih voda, njihova pročišćavanja i ispuštanja u prirodni prijamnik putem građevina za javnu odvodnju te upravljanje tim građevinama; javna odvodnja je i djelatnost pražnjenja i odvoza komunalnih otpadnih voda iz individualnih sustava odvodnje, što uključuje i pražnjenje i odvoz mulja iz malih sanitarnih uređaja; javna odvodnja ne uključuje pročišćavanje komunalnih otpadnih voda ako uređaj za pročišćavanje komunalnih

otpadnih voda nije u funkcionalnoj uporabi, a uključuje pročišćavanje ako je kolektor sustava javne odvodnje priključen na uređaj za pročišćavanje industrijskih otpadnih voda“ [21].

Shvaćanje da je vodovod prijeka potreba, a kanalizacija luksuz odavno je napušteno [15]. Kako je već navedeno u prethodnom poglavlju, kanalizacijski sustavi imali su za cilj odvođenje otpadnih i oborinskih voda na najbolji raspoloživi i najkraći način od mjesta nastanka otpadne vode do mjesta gdje se otpadna voda ulijeva u recipijent, a sukladno standardima koji su se mijenjali tijekom vremena [141].

Kanalizacija/sustav javne odvodnje je skup građevina i naprava kojima se otpadne vode skupljaju, odvede, čiste i ispuštaju u prijamnik. Općenito je kanalizacijom potrebno sve otpadne vode, uz što povoljnije sanitarne uvjete, što brže odstraniti iz ljudske blizine, s time da se prije ispuštanja u prijamnik očiste na stupanj propisan zakonom [142].

Sustav odvodnje čini skup građevinskih objekata koji služe za što brže odstranjivanje otpadnih voda iz čovjekove neposredne okoline i njihovo odvođenje do uređaja za pročišćavanje otpadnih voda ili direktnog ispusta u odgovarajući prijemnik [143]. Stoga se iz navedene definicije, ali i svih prethodno navedenih vidi da je glavni zadatak kanalizacijskog sustava da svu otpadnu vodu neškodljivo odvede na pogodno mjesto te da se ta voda uključi u kruženje vode na Zemlji [144]. Kanalizacijski sustav igra ključnu ulogu u okviru kruženja vodnih resursa [145].

U praksi se sustavi odvodnje obično nazivaju sustavima kanalizacije [146].

Kanalizacijski sustav je nešto mlađi od sustava za vodoopskrbu. Krajnja točka ovog sustava je uređaj za pročišćavanje otpadnih voda, odnosno ispust u recipijent. Najkraće rečeno, osnovni zadatci kanalizacijskog sustava su:

- neprekidno prikupljanje otpadnih voda na definiranom prostoru sustava
- sigurno transportiranje otpadnih voda, do uređaja za pročišćavanje otpadnih voda i
- osiguranje potrebnog tretmana prerade, do potrebne razine prije ispuštanja u recipijent [147].

Kod kanalizacijskog sustava otpadnih i oborinskih voda razlikuju se dvije vrste ciljeva koje je potrebno postići. To su temeljni i tehnološki cijevi.

Temeljni ciljevi za kanalizacijski sustav otpadnih i oborinskih voda su:

- sakupljanje svih otpadnih voda
- pročišćavanje svih otpadnih voda
- pročišćavanje otpadne vode do razine propisane zakonom
- imati održiva rješenja u skladu s vijekom trajanja građevine
- osigurati prihvatljivu razinu zaštite ljudi i njihove imovine i
- osigurati prihvatljivu razinu zaštite okoliša i vodnih resursa [148].

Tehnološki ciljevi za kanalizacijski sustav otpadnih i oborinskih voda su:

- što jednostavnije rješenje
- što manji troškovi izgradnje i
- što manji troškovi uporabe i održavanja [148].

Vrste kanalizacijskih sustava prema načinu prihvaćanja i odvodnje otpadne vode su:

- mješoviti ili skupni
- razdjelni ili separadni (odvojeni)
- polurazdjelni (djelomično razdjelni) i
- kombinirani.


Vrste kanalizacijskih sustava prema pogonskim osobinama sustava su:

- gravitacijski
- tlačni i
- vakuum [146].

U Europi se najviše koriste dvije glavne vrste kanalizacijskih sustava: razdjelni, mješoviti te modificirane verzije jednog od ta dva [149]. Tako, kod provedenog istraživanja u svrhu izrade doktorske disertacije vrste kanalizacijskih sustava su mješovita, razdjelna te kombinacije te dvije vrste. Stoga su u nastavku dani opisi kanalizacijskih sustava budući da utječu na način održavanja i troškove održavanja.

Mješoviti ili skupni tip kanalizacije (Slika 3.1.) je kanalizacijski sustav gdje se otpadne i oborinske vode s područja grada odvođe jednim odvodnim sustavom do uređaja za pročišćavanje otpadnih voda. Budući da je to stariji tip kanalizacije, on je karakterističan za većinu starih kanalizacija u Hrvatskoj, a koristio se kao najjeftinije rješenje skupljanja i

odvodnje urbanih otpadnih i oborinskih voda najkraćim putem do prijamnika. Mješovita kanalizacija karakteristična je s rasteretnim građevinama, tj. preljevima [150].



Slika 3.1. Mješoviti sustav odvodnje [151]


Preljevi su građevine pomoću kojih se za vrijeme kiša nepročišćene otpadne vode, zajedno s oborinskim vodama, prelijevaju iz kanalizacijskog sustava u prijamnike. Uloga preljeva u mješovitoj kanalizaciji u suštini je ekonomska. Prelijevanjem velikih količina oborinskih voda izravno u prijamnik smanjuje se protok vode u kanalizaciji nizvodno od rasteretne građevine i time znatno pojeftinjuje građenje i pogon kanalizacije. Što je to rasterećenje veće, to su i ekonomske uštede veće. U vremenu kada se nije poklanjala pažnja zaštiti voda i kada posljedice ispuštanja preljevniha voda u vode prijamnika nisu bile lako prepoznatljive, takvo je rješenje bilo logično i prihvatljivo. Međutim, porastom onečišćenja voda koje se javlja kao posljedica ubrzanog razvoja i rasta stanovništva, a posebno naglim rastom urbanih sredina koje generiraju velike količine otpadnih i onečišćenih oborinskih voda, takav koncept rješavanja odvodnje više nije prihvatljiv budući da su preljevne vode izvor nekontroliranog onečišćenja okoliša [150].

Odnos oborinske i drugih voda u kanalima je između 1 : 20 i 1 : 60 te su zbog toga za dimenzioniranje najvažnije oborinske vode. Ali, što se tiče trajanja otjecanja, najdulje trajanje imaju kućanske otpadne vode, a najkraće trajanje oborinske vode tako da je utjecaj kućanskih voda stalan [148] te one nepovoljno djeluju na kanalizacijski sustav zbog različitih kemijskih procesa i tvari koje negativno djeluju na kanalizacijske cijevi i sustav u cjelini. Ovaj kanalizacijski sustav karakteriziran je s dva režima tečenja: kišni i sušni. U kišnom režimu najveći dio voda koje otječu su oborinske vode, a manji dio čine otpadne vode. U sušnom je razdoblju obrnut slučaj – najveći dio čine otpadne vode, a manji dio oborinske vode. Ovisno o karakteristikama slivnog područja u ovom tipu kanalizacijskog sustava tijekom kišnog

razdoblja teče 10 do 30 puta veća količina vode nego u sušnom razdoblju [148]. U mješovitom sustavu odvodnje postoje određeni problemi u funkcioniranju sustava. Prvi i najvažniji je taj da će kanalizacija najveći dio vremena transportirati kućne otpadne vode koje su malog volumena te će se pojaviti taloženje otpada. Drugi problem je taj što će taj kanalizacijski sustav, koji inače prenosi malu količinu otpadne vode, kod velikih količina oborina morati podnijeti te količine kroz cijevi, a pogotovo crpne stanice i uređaji za pročišćavanje otpadnih voda [152]. Još jedan nedostatak mješovitog sustava je opasnost od plavljanja podruma i izlivanja vode po prometnicama kod začepjenja kanala ili prevelikog opterećenja kanala uslijed vrlo jakih pljuskova [153].


Kod razdjelnog ili separatnog sustava odvodnje (Slika 3.2.) uglavnom postoje dvije kanalizacijske mreže, i to jedna koja služi za odvođenje oborinskih voda i druga koja je namijenjena za kućanske i industrijske otpadne vode (ako na području postoji industrija). U ovom slučaju kanali oborinske vode su po dimenzijama isti kao u mješovitom sustavu, dok su kanali otpadnih voda prilagođeni njihovim količinama [146]. Uobičajeno su cijevi za odvodnju sanitarne vode iz kuća manjeg promjera od cijevi za odvodnju oborinskih voda [154]. Budući da su radovi na izgradnji kanalizacijske mreže skupi, puno gradova najprije izgradi kanalizacijsku mrežu za sanitarnu otpadnu vodu, a zatim se izgradi mreža za atmosfersku vodu [155].

Razdjelni sustav kanalizacije ima određene prednosti u usporedbi s mješovitim kanalizacijskim sustavom s obzirom na rad uređaja za pročišćavanje otpadnih voda. Dotoci na uređaj za pročišćavanje otpadnih voda su jednoličniji, u smislu manje varijacija količina i u pogledu ujednačenijih karakteristika, odnosno sastava otpadnih voda. U razdjelnom sustavu nema velikih varijacija sušno/kišno razdoblje, a koje su prisutne kod mješovitog sustava i zahtijevaju, i pored primjene kišnih rasterećenja, odgovarajuće dopunske objekte: dodatne taložnice, retencijske bazene i dr. za usklađivanje procesa pročišćavanja u kišnom periodu [156]. Obično su otpadne vode dosta onečišćene, a oborinske vode manje onečišćene [157] te je to prednost razdvajanja otpadnih voda kod razdjelnog sustava.



Slika 3.2. Razdjelni sustav odvodnje [151]


Polurazdjelni sustav odvodnje (Slika 3.3.) karakterizira ista mreža kao kod punog razdjelnog sustava, s razlikom što oborinska kanalizacija ima posebne dopunske uređaje pomoću kojih se voda od pranja ulica i atmosferske vode u vrijeme kiša malog intenziteta automatski odvodi u kanalizacijsku mrežu kućne kanalizacije. Na ovaj se način prvi, zagađeniji, manji dotoci oborinske vode odvođe na uređaj za pročišćavanje, a ostale, razmjerno čiste oborinske vode, ali znatno veće po količini, ispuštaju izravno u prijamnik [146].



Slika 3.3. Polurazdjelni sustav odvodnje [151]

Kombinirani sustavi odvodnje (Slika 3.4.) su sustavi koji imaju nekoliko zasebnih sustava (mješoviti, razdjelni, itd.). Ti sustavi nastaju kao rezultat razvojnih i ekoloških faktora koji se

javljaju tijekom vremena. U sušnom su razdoblju cijevi mješovite kanalizacije samo djelomično iskorištene, na njih je moguće povezati kućansku kanalizacijsku mrežu novih aglomeracija, a za oborinske vode, koje više ne mogu primiti postojeći kolektori mješovitog sustava, izgrađuje se odvojena oborinska kanalizacija s ispustom oborinskih voda u prijamnike [146].



Slika 3.4. Kombinirani sustav odvodnje [151]

Prethodno navedene vrste kanalizacijskih sustava klasificirane su prema načinu prihvatanja i odvodnje otpadnih voda, a osim njih već je prije navedeno da postoji i podjela prema režimu tečenja gdje se javljaju gravitacijski, tlačni i vakuumski [146].

Kada se govori o kanalizaciji, tada se uglavnom misli na gravitacijski sustav kanalizacije [146]. Gravitacijski sustav odvodnje otpadnih voda je općepoznat i prihvaćen u Hrvatskoj te se najviše primjenjuje. Karakteriziran je tečenjem otpadne vode sa slobodnim vodnim licem zbog visinskih razlika unutar dijelova kanala. Na najnižim dijelovima kanalizacijskog sustava postavljaju se crpne stanice koje su građevine s pripadnom elektrostrojarskom opremom. Crpne stanice su potrebne za podizanje otpadnih voda iz građevina ili područja (kanala) s nižih razina na više razine, odnosno dijelove kanala kada je pad kanala veći od nagiba terena. U slučaju kada bi se inzistiralo na kompletnoj gravitacijskoj odvodnji, to bi zahtijevalo dubine ugradnje kanala koje su daleko iznad ekonomski prihvatljivih koje iznose 6 do 7 m [158].

Tlačna kanalizacija ili kanalizacija pod pritiskom primjenjuje se u onim dijelovima kanalizacijske mreže gdje ne postoje uvjeti za gravitacijsku odvodnju [142], a tlačna kanalizacija kao cjelina je rijetkost [146]. Tlačna kanalizacija primjenjuje se od početka 1960-ih, a tijekom godina sustav se konstantno razvijao te danas u mnogim razvijenim zemljama predstavlja siguran tehničko-ekonomsko isplativi sustav odvodnje, posebno za mala ruralna naselja i izolirane gradske četvrti [158]. Općenito govoreći, sustav tlačne kanalizacije može činiti prstenastu ili razgranatu mrežu. Osim kanalizacijske mreže, tlačna kanalizacija može se izvesti kao pojedinačna dionica. Kod primjene u malim ruralnim naseljima, mreža sakupljača sastoji se od plitko ukopanih cjevovoda koji se polažu ispod dubine smrzavanja, a čiji promjer iznosi od 90 do 200 mm, nazivnog tlaka 10 bara. Tečenje pod tlakom potpomaže se dodatno propuhivanjem komprimiranim zrakom, pomoću zasebnih stanica koje tlače zrak u mreži za vrijeme početnog stanja podopterećenja. Tlačna kanalizacija može se primijeniti na svim vrstama terena neovisno o položaju ulaznih i izlaznih točaka, a trenutno se primjenjuje u naseljima s manje od 15 000 stanovnika [158].

Vakuumski kanalizacijski sustavi prvi su put upotrijebljeni još 1860. godine, a njihova masovnija primjena uslijedila je 1950. godine u Švedskoj [159]–[161]. Vakuumska kanalizacija koristi se u posebnim prilikama, npr. u sušnim područjima. Ona zahtijeva ugradnju posebnih cijevi, objekata i sanitarnih uređaja, pa nema širu primjenu. Radi na načelu podtlaka, tako da je cjelokupna mreža u podtlaku, a najveći podtlak je u sabirnom bazenu, odnosno izljevnom mjestu [146]. Vakuumska kanalizacija primjenjuje se u slučajevima kad je potpuno ravan teren, ako je visoka razina podzemnih voda, nepovoljan uzdužni profil, nestabilno tlo itd. [159]. Vakuumski kanalizacijski sustav u Republici Hrvatskoj postoji u Županji i jednom dijelu grada Siska. Relativno malo gradova u Hrvatskoj ima vakuumski sustav tako da se o njemu kao i o načinu uporabe i održavanja malo zna [161].

Osim gore navedenog tlačnog i vakuumskog sustava, važno je spomenuti i kondominijalni kanalizacijski sustav. To je alternativni kanalizacijski sustav koji je konceptualno sličan konvencionalnom gravitacijskom kanalizacijskom sustavu. Naziv „kondominijalni“ dolazi od portugalske imenice „*condominio*“ što u prijevodu znači stambeni blok. Kondominijalna kanalizacija je kanalizacijski sustav/mreža koja se sastoji od cijevi malih promjera koje su položene u plitke rovove pri što manjem nagibu s ciljem smanjenja ukupnih troškova izgradnje. Glavni razlog za korištenje ovoga naziva je činjenica da se kondominijalni kanalizacijski sustav polaže kao mreža cijevi najčešće unutar stambenog bloka, a ne na javnoj površini kao što je

slučaj kod konvencionalnih kanalizacijskih sustava. To znači da je ovaj sustav smješten na privatnom posjedu, u dvorištu ispred ili iza kućanstva te u nekim slučajevima ispod nogostupa stambenog bloka [162]. Budući da cijevima malog promjera treba manje vode za prijenos fekalija, na taj način štedi se voda [163]. Primjenjiv je za gusto naseljena periurbana područja, na različitim tlima, od pjeskovitih do stjenovitih, u područjima visokih podzemnih voda [1].

Kada se govori o potrebi inovacija postojećih kanalizacijskih sustava, odnosno uporabi alternativnih sustava i invenciji novih sustava, važno je reći kako su autori Öberg i sur. [164] zaključili kako postoji hitna potreba za inovacijama u sektoru odvodnje jer je konvencionalni model odvodnje predugotrajan i skup, a nema alternativa. Izazov su procijenili razvojem scenarija za 60 najbrže rastućih urbanih područja u svijetu. Uvidjeli su da bi većina gradova trebala izgraditi svoje kanalizacijske sustave po stopi koja je od deset do 50 puta viša od najviše stope za bilo koji projekt u bazi podataka Svjetske banke, što je nerealno [164]. Stoga, treba se fokusirati na nove nekonvencionalne metode odvodnje. Kako je prisutan stalni porast brige za zaštitu okoliša i održivo upravljanje sustavima odvodnje, to dovodi do sve kritičnijeg razmatranja i analiziranja postojećih sustava odvodnje. Također, razmatraju se načini projektiranja i obnove postojećih kanalizacijskih sustava kroz različite alternative. Novi kanalizacijski sustavi kao što je tlačna i vakuumska kanalizacija nalazit će sve veću primjenu i kod nas [141].

3.3. Održavanje kanalizacijskih sustava

Prema trenutno važećem Zakonu o gradnji (NN 153/13, 20/17, 39/19, 125/19) održavanje građevine je „izvedba građevinskih i drugih radova na postojećoj građevini radi očuvanja temeljnih zahtjeva za građevinu tijekom njezina trajanja, kojima se ne mijenja usklađenost građevine s lokacijskim uvjetima u skladu s kojima je izgrađena“ [57]. Prema tome, budući da je kanalizacijski sustav također građevina, slično vrijedi i za nju.

Građevine za odvodnju otpadnih voda kao što su kanali (cjevovodi) za prikupljanje i odvodnju otpadnih voda moraju se projektirati i graditi tako da se osigura vodonepropusnost istih. Također, neke građevine za javnu odvodnju otpadnih voda moraju se podvrgnuti kontroli ispravnosti na svojstvo strukturalne stabilnosti i osiguranja funkcionalnosti, a što je sve propisano u članku 6. Pravilnika o tehničkim zahtjevima za građevine odvodnje otpadnih voda, kao i rokovima obvezne kontrole ispravnosti građevina odvodnje i pročišćavanja otpadnih voda [165].

Kao i svaka građevina, tako i kanalizacijski sustav zastarijeva i propada tijekom vremena zbog utjecaja različitih fizičkih i kemijskih čimbenika. Kvarovi na ovoj kritičnoj infrastrukturi mogu uzrokovati društvene, okolišne i ekonomske utjecaje [166] te također imati katastrofalan utjecaj na promet i poslovanje [167]. Kanalizacijske cijevi jako su važan i kritičan dio kanalizacijskog sustava, ne samo zato što imaju važnu ulogu, već zato što je njihova svrha transport otpadne i oborinske vode do uređaja za pročišćavanja ili recipijenta te zato što su njihova izgradnja i popravak skupi [168]. Ograničenja u dostupnosti podataka i kvaliteti istih su uobičajeni za podatke o stanju kanalizacijskog sustava [169].

Dugoročno planiranje koristeći analizu troškova životnog ciklusa (engl. *Life cycle cost assessment, LCCA*) za kanalizacijske sustave može pomoći smanjiti troškove građenja, uporabe i troškova održavanja. Kada se odlučuje o načinima održavanja ili obnove kanalizacijskog sustava, važno je odlučiti prema troškovima životnog ciklusa umjesto oslanjanja samo na troškove izgradnje. Takav način odlučivanja o alternativama koristeći analizu troškova životnog ciklusa može u velikoj mjeri pomoći smanjenju kapitalnih troškova [170].

Održavanje se dijeli na dva tipa održavanja: preventivno održavanje i korektivno održavanje. Neki autori dijele održavanje na tri tipa: preventivno, korektivno i održavanje prema stanju [171]. Ako se koristi reaktivna strategija održavanja kanalizacijskog sustava, kanalizacija se ne čisti na nekoj regularnoj bazi, nego samo onda kada je potrebno kao što je u slučaju začepljenja. U slučaju preventivnog održavanja kanalizacijski sustav se održava u određenim vremenskim intervalima prema određenom planu održavanja i čišćenja [171]. Korektivno održavanje je loš način održavanja budući da ono dovodi do toga da kanalizacijski sustav bude određeno vrijeme izvan funkcije te je skupo, tako da kanalizacijski sustavi kojima je to glavni način održavanja neće dobro raditi i korisnici neće biti zadovoljni njime.

Održavanje prema stanju je takva strategija održavanja koja koristi sve dostupne metode radi određivanja tehničke razine stanja sustava i opreme s ciljem da se održavanju pristupi tek kada stanje komponenti sustava padne ispod određene kritične razine [172]. Ono se sastoji od tri glavna koraka: prikupljanja podataka, obrade podataka i odlučivanja o održavanju [173], [174]. Kod održavanja prema stanju odlučuje se, između ostaloga, o prikladnoj strategiji održavanja: redoslijedu radova, koji popravak ili zamjenu napraviti te prioritete poslova koji trebaju biti napravljeni [175].

Već kod projektiranja kanalizacije mora se misliti na mogućnosti održavanja, a upravo održavanje uvjetuje ograničenje minimalnih promjera cijevi. Tako npr. na početku dionica cijevi, količine kanalizacijskih voda često su vrlo male, posebno za odvodnju sanitarnih otpadnih voda u razdjelnom sustavu. Kada se to razmotri, onda bi, teoretski, bilo moguće koristiti jako male promjere cijevi na osnovi malih početnih protoka i uzdužnih nagiba, ali iskustvom iz prakse došlo se do zaključka da je primjena malih promjera cijevi nepovoljna te da često dolazi do začepljenja. Primjenom malih profila kanala znatno se povećavaju troškovi održavanja gravitacijskog kanalizacijskog sustava, a sve zbog potrebe čestog čišćenja i ispiranja. Zbog svega navedenog u javnim kanalizacijama s gravitacijskim tečenjem otpadne vode uobičajena je primjena najmanjih profila od 250 odnosno 300 mm [158]. Jedna od pojava koja je vrijedna pažnje, a može uzrokovati velike probleme u održavanju i funkcioniranju sustava, je pojava „uskih grla“. Takva pojava u kanalizacijskom sustavu izaziva višestruke štetne učinke – otežava nova priključenja građevina te izaziva stvaranje uspora u postojećoj mreži. Pojava uspora u mreži povećava mogućnost poplavlivanja otpadnom vodom prostorija koje se nalaze nisko kao što su podrumi, prostorije u suterenu i sl. Stoga, već kod projektiranja treba voditi računa o tome [126]. U velikoj mjeri životni vijek i trajnost sustava ovisi o pravilnom održavanju [176].

Ispravno funkcioniranje kanalizacijskog sustava uvjetovano je redovnim održavanjem svih dijelova kanalizacijskog sustava [15]. Dobro i pravilno održavanje sustava odvodnje osnovni je preduvjet za racionalno gospodarenje ovom skupom gradskom infrastrukturom, za adekvatne sanitarne uvjete u urbanoj sredini i za dobru zaštitu okoliša. Također, to je jedan od preduvjeta za održivi razvoj i zdravstveni standard urbane sredine, stoga mu se mora usmjeriti velika pozornost [146], [177], [178]. Pod pojmom dobro i pravilno održavanje smatra se odgovarajući način, odnosno strategija održavanja koja predviđa moguće nedostatke i kvarove (težište je na preventivnom održavanju), te je ekonomski učinkovita [179]. Troškovi korektivnih akcija, tj. održavanja su dva do deset puta veći nego troškovi preventivnog održavanja [180], stoga se preventivnim akcijama treba dati prednost. Također, neočekivani kvarovi, puknuća cijevi, zastoji u radu ili bilo što drugo kod kanalizacijskog sustava može prouzročiti onečišćenje okoliša, poplavu ili neki drugi problem [181].

Za izgradnju kanalizacijskog sustava, kao jednog od važnijih infrastrukturnih sustava, potrebna je velika količina novčanih sredstava. Međutim, i održavanje postojećih sustava ne smije biti zanemareno [182], a troškovi održavanja su također visoki. U mnogo područja određene države

problematika preventivnog održavanja kanalizacijskog sustava se jako zanemaruje [183]. Svakoje kanalizacijskoj mreži neophodno je održavanje. Cilj održavanja je da se kanalizacijskom sustavu maksimalno produži vijek trajanja i razina funkcionalnosti. To se ostvaruje kroz različite aktivnosti održavanja [184]. Ispravna uporaba i održavanje kanalizacijskog sustava su važni kako bi se osigurao ispravan protok kroz kanalizacijske cijevi, prevenirala začepjenja i istjecanja otpadne vode [185].

Kanalizacijski sustav, odnosno kanalizacijska mreža podložna je kvarovima i mora se održavati. Poznato je da su kvarovima podložne one mreže koje su jako stare i koje imaju:

- uzdužne padove manje od minimalno dozvoljenih
- male minimalne profile cijevi
- loše izvedene spojeve, uzdužne padove i okna
- veći broj napuknuća, deformacija i lomova zbog loše ugradnje i
- nedisciplinirane korisnike koji u kanalizaciju nedopušteno ispuštaju tvari i stvari koje ne bi smjeli ispuštati [186].

Neki od uvjeta za dobro održavanje kanalizacijskog sustava su upoznatost sa sustavom, njegovim karakteristikama, dovoljan broj zaposlenika koji su dobro organizirani te dostatan iznos financijskih resursa. Svi ovi uvjeti su međusobno povezani. Bez dostatnih financijskih resursa, između ostaloga, pretpostavlja se da neće biti dovoljan broj zaposlenika koji održavaju kanalizacijski sustav. Bez dobre organizacije i plana održavanja zaposlenici neće moći učinkovito održavati sustav, iako ih ima dovoljan broj. Čak i ako su ti uvjeti zadovoljeni, bez dobrog poznavanja kanalizacijskog sustava ne može se računati na adekvatnu razinu održavanja kanalizacijskog sustava. Budući da je svaki kanalizacijski sustav jedinstven za svoju okolinu, to se javlja zahtjev i potreba za jedinstvenim pristupom njegovom upravljanju i održavanju. Svaki upravljački dio kanalizacijskog sustava zahtijeva prikladni plan upravljanja i održavanja [146], [187].

Sve aktivnosti na održavanju moraju biti nadzirane kako bi se osiguralo da se rade pažljivo i sigurno, prema standardima, uz prihvatljive troškove i unutar zadanog vremena. Dobar nadzor temelji se na:

- poznavanju posla koji treba biti obavljen
- važnosti obavljenog posla
- određivanju odgovornih osoba i

- specifikaciji mjerljivih standarda. Sve ovo zahtijeva dobro obrazovanje i uvježbanost nadzora [152].

Mnogo kvarova u kanalizacijskom sustavu nisu slučajni, već predstavljaju određenu promjenu kojoj je prethodilo postupno propadanje i pogoršanje uvjeta [188] što govori u prilog važnosti preventivnog održavanja. Iz svega prethodno navedenog može se zaključiti da je održavanje kanalizacijskog sustava složen zadatak [189], [190].

Kod upravljanja kanalizacijskim sustavom jedan problem je taj što stanje ovog podzemnog infrastrukturnog sustava nije u potpunosti dokumentirano. Također, puno gradova nema podatke o prošlom, ali i sadašnjem stanju kanalizacije što onemogućava procjenu prioriteta obnove [191] i tako opet otežava proračun potrebnog budžeta za održavanje. A zadatak određivanja budžeta je veliki problem kod svih aktivnosti održavanja kanalizacijskog sustava [192].

Jedan veliki izazov je što su kanalizacijske cijevi pod zemljom te je veoma teško otkriti cijevi koje imaju povećani rizik od puknuća ili kvara neke druge vrste. Također, jasno je da je pregled svih kanalizacijskih cijevi nemoguć zbog ograničenog budžeta, vremena te dostupnih tehnologija za procjenu stanja kanalizacijskog sustava [193].

Preventivno održavanje može se nazvati i redovno održavanje. Redovno održavanje kanalizacijskog sustava većinom se svodi na snimanje stanja, čišćenje cijevi i kanala, kišnih rešetki i svih objekata (npr. crpne stanice), izmjenu dotrajalih dionica cijevi te pregled stanja svih objekata kanalizacijske mreže. Čišćenje je potrebno provoditi zbog taloženja pijeska i mulja, ulaženja korijenja drveća u cijevi ili začepljenja uzrokovanih neodgovornim bacanjem otpadaka korisnika u kanalizaciju [146]. Da bi se osigurao rad i uporaba kanalizacijskog sustava prema namjeni za koju je sustav projektiran, održavanje bi trebalo težiti minimaliziranju broja začepljenja i širenja neugodnih mirisa. Kako bi se to postiglo, kanalizacijski sustav čisti se prema unaprijed određenom rasporedu održavanja i čišćenja kako bi se uklonili nakupljeni ostaci i talog u kanalizacijskim cijevima. Nakupljeni ostaci u cijevima smanjuju kapacitet cijevi, tj. smanjuje se promjer cijevi te eventualno dovode do začepljenja što može rezultirati izlivanjem otpadne vode na površinu ili u okolne zgrade koje imaju podzemne etaže. Korijenje i korozija također mogu prouzročiti ozbiljnu štetu cjevovodnom sustavu [187]. Uobičajeni životni vijek kanalizacijskih cijevi je od 50 do 100 godina [38]. Istraživanje koje je proveo Bauer pokazalo je da iskopane kanalizacijske cijevi nakon 15 godina

ne pokazuju oštećenja u tom razdoblju [194], a istraživanje drugog autora je pokazalo da na iskopanim kanalizacijskim cijevima starima 25 godina također nema oštećenja te je zaključeno kako PVC kanalizacijske cijevi mogu trajati barem 100 godina [195]. Nadalje, neka istraživanja provedena na iskopanim kanalizacijskim cijevima pokazuju kako je vijek kanalizacijskih cijevi od 100 do čak 300 godina [196]. Međutim, očekivani životni vijek kanalizacijskih cijevi je od 40 do 80 godina. Različiti faktori poput načina gradnje, tla, geoloških uvjeta, tokova, opterećenja, održavanja i starenja materijala cijevi odredit će stvarni životni vijek kanalizacijskih cijevi [197].

Jedan od sustava koji mogu biti od velike pomoći je geografski informacijski sustav (GIS) koji osigurava informacije poput položaja kanalizacije, priključaka korisnika, vrste korištenja zemljišta, mjesta oštećenja, planiranih mjesta popravaka [198]. Stoga, kanalizacijski sustavi koji koriste GIS sustav podrške su u prednosti što se tiče upravljanja i održavanja u odnosu na one koji ne koriste GIS, a pogotovo ako su većih duljina. Kanalizacijske cijevi jedna su od rijetko pregledavane infrastrukture [169], [199] te ih je i iz tog razloga važno redovito pregledavati i provoditi snimanje, pregled, čišćenje i popravak. Jedna od najčešćih aktivnosti održavanja kanalizacijskog sustava, odnosno kanalizacijskih cijevi je čišćenje kanalizacijskih cijevi.

Za čišćenje kanalizacijskog sustava potrebni su alati kao što je pijuk, tronožac, zastavice upozorenja, baterija, lampe, užad, kuke itd., te specijalna oprema i uređaji (četke, lanci za razbijanje taloga, noževi za sječu i čupanje korijenja, posude za izvlačenje mulja itd.).

Čišćenje kanalizacije može biti:





- 1) mehaničkim sredstvima i
- 2) ispiranjem.

Čišćenje mehaničkim sredstvima radi se specijalnim uređajima kao što su četke, lanci za razbijanje taloga, noževi za sječenje i čupanje korijenja, kuke, posude za izvlačenje mulja. Ovi se alati vuku kroz kanal ručno ili mehanički [146]. Za navedene poslove postoje različiti modeli strojeva za čišćenje na koje je moguće montirati različite nastavke za čišćenje, ovisno o tome što se namjerava čistiti – korijenje, talog, probiti začepljenje, izvaditi krpe, naći izgubljeni sajlu itd.

Stroj koji se koristi za čišćenje kanalizacijskih cijevi i priključaka pomoću sajle često se koristi budući da je učinkovit kod čišćenja, što je najčešća aktivnost održavanja kanalizacijskog

sustava. Kako bi se moglo očistiti – odčepiti različite zastoje u cijevima – potrebno je koristiti različite vrste svrdala. Različite vrste svrdala, odnosno nastavaka koje može koristiti stroj za čišćenje kanalizacijskih cijevi prikazane su u tablici 3.1. Navedeni stroj koristi se za čišćenje kanalizacijskih cijevi kod kućnih priključaka.

Tablica 3.1. Primjeri različitih modela svrdala za stroj za čišćenje kanalizacije (izrada autora prema: [200])


Svrdlo s padajućom glavom	Ravno svrdlo	Ljevkasto svrdlo	Kukasto svrdlo
			
Povratno svrdlo	Lopatasto svrdlo	Četverolisni pilasti sjekač	Rezač maziva
			

Osim čišćenja sajlama i različitim nastavcima učestalije se radi čišćenje ispiranjem vodom pod velikom pritiskom.


U novije vrijeme, čišćenje pod velikim pritiskom postalo je najviše korištena metoda za održavanje kapaciteta protočnosti kod malih i srednjih promjera cijevi kanalizacijskih sustava [201]. Ispiranje kanalizacije pod pritiskom je takav način čišćenja gdje se voda pod jako visokim tlakom pomoću visokotlačnih cijevi i mlaznica koristi kako bi se kanalizacijske cijevi isprale i očistile od nakupljenih nečistoća. Mlaznica ima više vrsta, a obično mlaznica ima jedan otvor naprijed te više manjih otvora koji su usmjereni nazad tako da ispiru stijenke cijevi. Sva navedena oprema (visokotlačne cijevi, spremnik za vodu i spremnik za otpadnu vodu, mlaznice, visokotlačna pumpa i drugo) nalazi se na kamionima koji su specijalno opremljeni,

odnosno proizvedeni za poslove čišćenja kanalizacijskog sustava. Obično takvi kamioni imaju i spremnik za otpadne vode tako da se nakupljena nečistoća ili talog može usisati pomoću crpke u spremnik na kamionu te odložiti na prikladan način i mjesto. Svako poduzeće koje upravlja većim kanalizacijskom sustavom trebalo bi imati odgovarajući broj takvih specijalnih kamiona i sve potrebne opreme budući da je uz odgovarajuću opremu moguće pravilno i redovito održavanje.

Mlaznica i kamion za ispiranje kanalizacije visokim pritiskom prikazani su na slikama 3.5. i 3.6.



Slika 3.5. Mlaznice za čišćenje kanalizacije [202]



Slika 3.6. Kamion za čišćenje cijevi vodom pod pritiskom [203]

Također, posebno je važno napomenuti kako je potrebno voditi računa o vrstama drveća koje se sadi kod kanalizacije i mjestu gdje se ono sadi. Tijekom samog postavljanja kanalizacijskih cijevi važno je voditi računa da su svi spojevi dobro zabrtvljeni, bilo pomoću gumenih brtvi

bilo na neke druge načine, te da je napravljeno ispitivanje cijevi na vodonepropusnost. Također, dionice (duljine) cijevi trebaju biti što dulje kako bi se broj spojeva i potrebnih brtvljenja smanjio na najmanju moguću mjeru [36]. Što se tiče odabira vrste drveća koje se sadi u blizini cijevi, treba birati drveće koje ima slabiji, manji korijenski sustav i manjeg je rasta te samim time ima manju mogućnost prodora korijenja u cijevi [204]. Korijenje drveća u više od 50 % slučajeva uzrokuje začepljenja cijevi tako da su troškovi uklanjanja korijenja iz kanalizacijskih cijevi znatni. Kod cijevi manjeg promjera nije neuobičajeno uklanjanje korijenja svake godine ili svake druge godine [205].

Čišćenje kanalizacije u većini gradova danas više nije problem i ne čini neku poteškoću, budući da su na raspolaganju različiti alati, strojevi te specijalna vozila koja uvelike olakšavaju navedene poslove. Za pravilno funkcioniranje kanalizacije neophodno je uredno održavanje u fazi uporabe [134]. Kod utvrđivanja mogućih kvarova u kanalizacijskoj mreži, budući da se većinom koristi gravitacijski sustav kanalizacije, mjesta kvarova je teško utvrditi jer se curenje vode ne čuje [144] te je stoga potrebno pažljivo provoditi inspekciju, održavanje i popravke kanalizacije. Prema svemu navedenom vidi se da je održavanje kanalizacije veoma složen i zahtijevan posao koji zahtijeva dosta novčanih sredstava.

Kada se govori o održavanju kanalizacije, potrebno je spomenuti kako je u kanalizacijskoj mreži neophodna deratizacija. U kanalizacijskoj mreži potrebna je deratizacija jer se u njoj nalazi stalni izvor hrane za štakore, ima povoljne mikroklimatske uvjete za rast i razmnožavanje štakora te je kanalizacijska mreža najjednostavnija i najbolja komunikacija za štakore. Deratizacija kanalizacijske mreže radi se na dva načina. Prvi način je defenzivni način gdje se štakorima onemogućava komunikacija preko interne kanalizacije i kućnih priključaka pomoću različitih poklopaca. Drugi način je ofenzivni gdje se koriste otrovi. Danas se za deratizaciju kanalizacijske mreže koriste isključivo parafinski blokovi [206].

Postoje različite metode inspekcije i pregleda kanalizacijskih cijevi, a one su pregledno prikazane u tablici 3.2. Najčešće se upotrebljava vizualna inspekcija pomoću CCTV (engl. *closed-circuit television* – snimanje kamerama, televizijska inspekcija) opreme ili ulaženjem radnika u kanalizaciju gdje je to moguće [207]. Navedena inspekcija pomoću CCTV opreme je desetljećima bila korištena za pregled stanja kanalizacijskog sustava i unutarnjih površina cijevi [208].

Tablica 3.2. Metode pregleda i inspekcije kanalizacijskog sustava [209]

Tehnologija		Vrsta kanalizacije			Vrsta materijala	Promjer cijevi (mm)	Detektirani problem			
		Gravitacijska	Tlačna	Priključci			Stanje unutar cijevi	Stijenka cijevi	Curenje	Oslonac cijevi
Kamere	Digitalne kamere	•			A	150-1500	•	•	•	
	Zoom kamere	•			A	>150	•	•	•	
	Endoskop kamera			•	A	25-300	•	•	•	
Akustična	Detektori curenja	•	•		A	≥100			•	
	Sustav za monitoring		•		PCCP	≥450		•		
	Sonar/ultrazvuk	•	•		A	≥50	•	•		
Elektro/ Elektromagnet ski	Elektronska detekcija curenja	•	•	•	NM	≥75			•	
	Polje elektromagnetskog strujanja (RFEC)	•	•	•	metal, PCCP	≥50		•	•	
	Magnetski tok	•	•	•	metal	50-1400		•		
Laser	Lasersko profiliranje	•	•		A	100-4000	•	•		
Inovativne tehnologije	Gama zračenje	•	•	•	beton	N.D.				•
	Georadar	•	•	•	A	N.D.			•	•
	Infracrvena termografija	•	•	•	A	N.D.			•	•
	Mikro defleksija	•			opeka	N.D.		•		•
	Impact echo / SASW	•			opeka/ beton	>1800		•		

Napomene – skraćenice u tablici:

A – bilo koja vrsta materijala od koje su kanalizacijske cijevi napravljene (od engl. *Any*)

Impact echo – Impact echo metoda

N.D. – nije definirano

NM – nemetalno

PCCP – prenapregnuta betonska okrugla cijev (od engl. *Pre-stressed cylindrical concrete pipe*)

RFEC – polje elektromagnetskog strujanja (od engl. *Remote Field Eddy Current*)

SASW – spektralna analiza površinskih valova (od engl. *Spectral analysis of surface waves*)

Navedeno je važno znati i uzeti u obzir već kod projektiranja kanalizacijskog sustava i odabira varijantnih rješenja, kao i kod odabira vrste kanalizacijske cijevi. Također, kod održavanja tablica 3.3. daje određena najčešća oštećenja kanalizacijskih cijevi što pomaže kod pregleda i inspekcije cijevi i lakše uočavanje istog.

Oštećenja na kanalizacijskom sustavu mogu se kategorizirati kao servisna ili strukturalna. Strukturalna oštećenja uključuju pukotine, lomove, deformacije, izvlačenje spojeva te otvorene spojeve. Servisna oštećenja su ulazak korijenja u cijev, različite zapreke (začepljenja) te taloženje u cijevima. Također, oštećenja na cijevima mogu se klasificirati prema tome je li oštećenje na ili unutar cijevi, na stijenci cijevi, propušta li ili je došlo do denivelacije cijevi [209].

Najčešća oštećenja kanalizacijskih sustava su pukotine/slomljene cijevi, ulazak korijenja u cijev, taloženje sedimenta, korozija, izvlačenje spojeva, curenje te ulegnuća cijevi. Međutim, oštećenja cijevi variraju ovisno o vrsti cijevi (materijalu od kojeg je napravljena) te promjeru cijevi. Budući da su kanalizacijski sustavi većinom gravitacijski te su napravljeni od različitih materijala, oni su podložni različitim vrstama oštećenja [209].

Najčešći kvarovi i oštećenja koji se javljaju kod kanalizacijskih cijevi dani su u tablici 3.3.

Tablica 3.3. Najčešća oštećenja kod kanalizacijskih cijevi [210], [211]

Oštećenje-defekt	Vrsta kanalizacijske cijevi								
	C	AC	PCCP	CI	S	CL	Br	PVC	HDPE
Korijenje	•	•	•	•	•	•	•		•
Masti i ulja (FOG)	•	•	•	•		•	•	•	•
Pukotine	•	•				•			
Unutarnja korozija	•	•	•	•	•				
Vanjska korozija			•	•	•				
Infiltracija i utjecanje (I/I)	•	•		•		•		•	
I/I spojnice	•		•		•				
I/I kućnih priključaka				•					•
Krivi postupak				•				•	•
Krivi način spajanja		•		•		•			
Deformacija					•			•	•
Ostalo	1						2	3	4

Napomene – skraćenice u tablici:

AC – azbest cement

Br – opeka

C – beton

CI – lijevano željezo

CL – glina

FOG – masti i ulja

HDPE – polietilen visoke gustoće

I/I – infiltracija podzemne vode i utjecanje oborina

PCCP – prednapregnuta betonska kružna cijev

PVC – polivinilklorid

S – čelik

1 – oštećenje na brtvljenju, 2 – nedostaju opeke, 3 – kućni priključci, 4 – tlačno ispitivanje

Kada se govori o održavanju kanalizacijskog sustava, potrebno je spomenuti i metode njegove obnove i popravka. Uobičajeno je da se, kada se određena kanalizacijska cijev slomi, dogodi

puknuće, brtveni prstenovi više nisu ispravni, ili u nekom drugom slučaju, radi iskop cijevi kako bi se vidjelo što se točno dogodilo, odnosno kako bi se cijev mogla zamijeniti. Takav način prouzrokuje dosta problema u funkcioniranju normalnog pješačkog i cestovnog prometa, narušava izgled okoliša, a nerijetko se promet mora zatvoriti kako bi se mogao napraviti iskop cijevi, zamjena cijevi te vraćanje svega u prvobitno stanje. Jedan primjer iskopa prikazan je na slici 3.7.

Kako bi se obnovila/popravila kanalizacijska cijev, uobičajeno se takva vrsta radova sastoji od šest faza:

- 1) uklanjanje sloja asfalta i odlaganje materijala
- 2) iskop rova
- 3) uklanjanje stare cijevi
- 4) postavljanje nove cijevi
- 5) zatrpavanje rova i
- 6) ponovno polaganje sloja asfalta, odnosno vraćanje u prvobitno stanje [212].



Slika 3.7. Prikaz postavljanja nove kanalizacijske cijevi i izrade kontrolnog okna

Kako je prikazano na slici 3.7., vidljivo je da održavanje kanalizacijskog sustava, odnosno popravak, uzrokuje velike probleme u funkcioniranju dijela ulice ili naselja gdje se izvode

radovi. Kako je kanalizacijska cijev pod zemljom, to njezina zamjena zahtijeva iskop što stvara probleme u normalnom odvijanju pješačkog i cestovnog prometa, narušava se izgled okoliša, oštećuju završne obloge (asfalt, beton, opločnici i sl.), skupa je. Stoga je potrebno voditi računa o izgradnji i održavanju kanalizacijskog sustava kako bi se zamjena kanalizacijskih cijevi radila što rjeđe, odnosno samo kada je to neophodno.

U održavanju kanalizacije revolucionarni se pomak dogodio uvođenjem opreme za održavanje i sanaciju kanalske mreže kojom se upravlja izvana. Operativne su se mogućnosti službi za održavanje bitno popravile, a smanjen je udio neugodnoga i prljavoga ljudskog rada [186].

Metode obnove i zamjene cijevi bez iskopa u svjetskoj su praksi poznate pod nazivom bezrovovske metode [213]. Neke metode bezrovovske obnove kanalizacijskih cijevi karakterizira da se unutar postojeće cijevi umeće nova te se na taj način radi popravak cijevi (npr. CIPP metoda), a kod nekih kao što su metoda linijske ekspanzije i metoda proboja, postojeća cijev se koristi kako bi se zamijenila novom cijevi [214].

U nastavku će se samo navesti nekoliko najpoznatijih.

Neke metode bezrovovske obnove i popravka kanalizacijskih cijevi su:

- metoda proboja ili linijske ekspanzije (engl. *Pipe Bursting, In-Line Expansion*)
- umetanje nove cijevi u postojeću, metoda klizajuće obloge (engl. *Sliplining*)
- metoda sanacije u mjestu (engl. *Cured-In-Place Pipe, CIPP*) i
- metoda obloge s promjenjivim poprečnim presjekom (engl. *Modified Cross Section Liner*) [215].

Tehnologija bezrovovske obnove cijevi ima sljedeće povoljne značajke u usporedbi s tradicionalnim načinom iskopa rovova za polaganje cijevi, odnosno zamjene cijevi:

- Nisu potrebni iskopi između pristupnih mjesta (često postojećih šahtova) koji su uglavnom postavljeni na znatnoj udaljenosti.
- Potreban je određeni, manji broj građevinskih strojeva i aktivnosti koje su koncentrirane samo na mjestima gdje se radi, tj. pristupnim mjestima gdje se, obično, uvode nove cijevi.
- Moguće je kontinuirano radno okruženje od 24 sata uz minimalno ometanje u radu okolnih zgrada, odnosno ometanje susjedstva gdje se radi.

- Znatno je manja vidljivost građevinskih aktivnosti što može dovesti do manjeg broja potraživanja od osiguranja i pritužbi građana.
- Rezultat dovršenog i obnovljenog kanalizacijskog sustava (cijevi) u nekim je slučajevima bolji i čvršći od onog koji je bio prije, izvornog.
- Krajnji postignut obnovljeni kanalizacijski sustav može imati bolje karakteristike protoka od izvornog kanalizacijskog sustava prije obnove [216].

Kod obnove kanalizacije treba puno pažnje pokloniti sigurnosti na radu svih radnika, a pogotovo onih koji ulaze unutar kanalizacije. Stoga je obvezna uporaba osobne zaštitne opreme kao što su kacige, rukavice, užadi, pojasevi, aparati za disanje i sl. [217].

Naravno, čak i uz dobar plan i program održavanja kanalizacijskog sustava, problemi se mogu javiti zbog starosti sustava, puknuća i starenja materijala koji su korišteni kod građenja kanalizacijskog sustava, dodatnih, prekomjernih korisnika i priključaka na sustav ili bilo kojih drugih faktora koji ograničavaju kapacitete kanalizacije. Međutim, bez obzira na to, dobar i kvalitetan plan održavanja sigurno će uštedjeti novčana sredstva na duge staze jer će spriječiti razvoj kvarova i nedostataka koji s vremenom mogu prerasti u veće kvarove koji bi sigurno bili skuplji za otklanjanje [218].

Korektivno održavanje može se nazvati i incidentno održavanje jer se ono javlja tek kada se dogodi neki incident na koji je potrebno odgovoriti u što kraćem roku. Incidentne situacije mogu biti pucanje cijevi, prevelika opterećenja, začepljenja otpadom ili različitim materijalima. Pucanje cijevi može dovesti do urušavanja ulica, propadanja ulica, cesta, pločnika te zagađenja okoliša jer otpadna voda istječe u okoliš [146].

Inženjeri diljem svijeta shvaćaju da proaktivno i preventivno održavanje kanalizacijskih sustava je često troškovno povoljnije nego tradicionalni pristup održavanju – reaktivno održavanje [219]. Kod građevina se preventivnom održavanju treba dati prednosti budući da ono produljuje uporabni vijek građevnih elemenata, smanjuje moguće kvarove na najmanju moguću mjeru i osigurava korisnicima neprekinutu i prikladnu uporabu [220].

Zakonska regulativa koja obuhvaća pojmove građevina za javnu odvodnju, daje osnovne podatke o kanalizacijskim sustavima u RH i definira određene uvjete za obavljanje djelatnosti javne odvodnje je sljedeća:

- Zakon o vodama (NN 66/19, 84/21)
- Zakon o vodnim uslugama (NN 66/19)

- Plan upravljanja vodnim područjima 2016. – 2021. (NN 66/16)
- Strategija upravljanja vodama (NN 91/08)
- Pravilnik o posebnim uvjetima za obavljanje djelatnosti javne odvodnje (NN 28/11, 16/14)
- Pravilnik o tehničkim zahtjevima za građevine odvodnje otpadnih voda, kao i rokovima obvezne kontrole ispravnosti građevina odvodnje i pročišćavanja otpadnih voda (NN 3/11).

3.4. Stanje usluga odvodnje i kanalizacijskog sustava u državama u okruženju i Republici Hrvatskoj

U Republici Hrvatskoj prevladava mješoviti sustav odvodnje, dok je razdjelni sustav rjeđi. U kontinentalnom dijelu Republike Hrvatske, odnosno crnomorskom slivu prevladava mješoviti kanalizacijski sustav, a u jadranskom slivu prevladava razdjelni sustav. Kako je, općenito gledajući, kanalizacijski sustav star u gradovima u Hrvatskoj, može se pretpostaviti da je većina kanalizacijskih sustava dosta vodopropusna [221], [222]. Bez sustava javne odvodnje je 54 % stanovništva, i to 56 % stanovništva na vodnom području rijeke Dunav, dok je na jadranskom području to 52 % [223].


U 2019. godini na području Republike Hrvatske bilo je 134 poduzeća čija je djelatnost skupljanje, pročišćavanje i opskrba vodom [224] što se prema Nacionalnoj klasifikaciji djelatnosti iz 2007. godine (NKD 2007.) nalazi pod šifrom E 3600 [225]. Nadalje, poduzeća čija je djelatnost prema NKD-u 2007. uklanjanje otpadnih voda (E 3700) u 2019. godini bilo je 81 [224].

Kako bi se moglo vidjeti stanje Republike Hrvatske u smislu dostupnosti i razvijenosti usluga odvodnje, u tablici 3.4. prikazani su podatci o priključenosti na kanalizaciju, priključenosti na uređaj za pročišćavanje otpadnih voda (UPOV) i pristupu zahodu na ispiranje za Republiku Hrvatsku i određene države u okruženju kao što su: Albanija, Austrija, Bosna i Hercegovina, Bugarska, Crna Gora, Rumunjska, Slovačka, Slovenija i Srbija.

Grafički prikaz prikupljenih podataka dan je na slici 3.8.

Tablica 3.4. Priključenost na kanalizaciju, priključenost na uređaj za pročišćavanje otpadnih voda i pristup zahodu na ispiranje za promatrane države (izrada autora prema: [226]–[238])

Država	Priključenost na javnu kanalizaciju [%]	Priključenost na UPOV [%]	Pristup zahodu na ispiranje [%]
Albanija	55	39	89
Austrija	94	95	99
Bosna i Hercegovina	51	1,9	91
Bugarska	66	62	67
Crna Gora	44	18	89
Hrvatska	58	53	95
Rumunjska	46	46	61
Slovačka	69	61	97
Slovenija	52	58	99
Srbija	55	12	93




Slika 3.8. Priključenost na kanalizaciju, priključenost na UPOV i pristup zahodu na ispiranje za deset promatranih država

Također, za iste, prethodno navedene države prikazane su duljine kanalizacijskih mreža te prosječan broj priključaka na odvodnju po kilometru kanalizacijske mreže (Tablica 3.5.).

Tablica 3.5. Duljine kanalizacijske mreže i broj priključaka po km mreže za promatrane države (izrada autora prema: [226]–[238])

Država	Duljina kanalizacijske mreže [km]	Prosječan broj priključaka na odvodnju po km mreže [kom]
Albanija	1.752	221
Austrija	96.200	-
Bosna i Hercegovina	4.339	70
Bugarska	-	-
Crna Gora	-	-
Hrvatska	10.539	46
Rumunjska	26.500	-
Slovačka	11.655	36
Slovenija	8.501	31
Srbija	15.159	53

Duljine kanalizacijske mreže za promatranih deset država prikazane su na slici 3.9.



Slika 3.9. Duljina kanalizacijske mreže za deset promatranih država

Prema tablici 3.6. prikazane su duljine kanalizacijskog sustava, broj kanalizacijskih priključaka te ostali analizirani podatci u Republici Hrvatskoj za razdoblje od 2013. do 2020. godine budući da su zaključno s 2020. godinom dostupni relativno potpuni podatci na službenim internetskim stranicama Državnog zavoda za statistiku Republike Hrvatske.

Tablica 3.6. Prikaz određenih pokazatelja kanalizacijskih sustava za Republiku Hrvatsku (izrada autora prema: [239], [240])

Pokazatelj	Godina							
	2013.	2014.	2015.	2016.	2017.	2018.	2019.	2020.
Broj crpnih postrojenja [kom]	909	963	1.157	1.279	1.561	n.a.	n.a.	n.a.
Ukupna duljina zatvorene kanalizacijske mreže [km]	9.324	9.649	10.493	10.885	12.047	12.529	13.168	13.453
Duljina separacijskog sustava [km]	2.716	2.980	3.214	3.365	4.523	n.a.	n.a.	n.a.
Broj kanal. priključaka [kom]	502.410	521.882	521.882	555.147	568.842	587.922	616.977	n.a.
Broj uličnih slivnika [kom]	194.425	196.607	199.250	202.445	201.764	n.a.	n.a.	n.a.
Broj UPOV-a [kom]	118	126	133	139	150	151	166	174
Količina otpadne vode [000 m³]	343.544	333.353	327.872	334.790	312.022	335.807	361.359	356.149

U Republici Hrvatskoj sva poduzeća koja se bave djelatnošću javne odvodnje moraju ispunjavati određene posebne uvjete u smislu tehničke opremljenosti te brojnosti i stručnosti zaposlenika, a što je propisano u Pravilniku o posebnim uvjetima za obavljanje djelatnosti javne odvodnje [241].

4. PRIKUPLJANJE I OBRADA PODATAKA

Budući da je cilj doktorske disertacije izrada modela pomoću kojeg će se moći procijeniti troškove održavanja kanalizacijskog sustava, to je za potrebe izrade navedenog modela kreiran upitnik pomoću kojeg su se prikupljali potrebni podatci. Primjenom modela za procjenu troškova održavanja kanalizacijskog sustava može se povećati učinkovitost održavanja istog budući da bi tako bilo moguće planirati određeni budžet za tu svrhu.

4.1. Upitnik

Kako bi se napravila baza podataka koja je neophodna kod izrade regresijskog modela procjene troškova održavanja kanalizacijskog sustava, napravljen je upitnik. Upitnik koji je poslan i pomoću kojeg su prikupljeni podatci nalazi se u Prilogu 1. Uz upitnik, poslana je i zamolba za dostavu podataka (nalazi se u Prilogu 1.).

Upitnik i zamolba poslani su poduzećima elektronskom poštom (*e-mailom*), neka poduzeća su kontaktirana telefonski, a kod nekih se otišlo osobno, a sve s razlogom kako bi se pokušalo prikupiti što više upotrebljivih upitnika koji će poslužiti u daljnjoj analizi i istraživanju.

Budući da je istraživanje provedeno 2019. godine, tražili su se podatci zaključno s 2018. godinom jer za 2019. godinu nisu bili dostupni potpuni podatci. Razdoblje za koje su traženi podatci je 10 godina, odnosno prva godina bila je 2009., a zadnja je bila 2018. godina.

Upitnik se sastojao od pet dijelova:

1. Opći podatci o poduzeću, opremi i održavanju

U tom dijelu traženi su podatci o nazivu poduzeća, adresi, broju zaposlenih na poslovima održavanja kanalizacijskog sustava, ukupan broj zaposlenih u poduzeću, područje (naselja) na kojima se obavlja djelatnost odvođenja otpadnih voda, broj vozila za održavanje kanalizacijskog sustava (bageri, specijalna vozila za čišćenje kanalizacije i ostalo), posjeduje li poduzeće opremu za CCTV snimanje, je li kanalizacijski sustav prikazan u GIS-u, zna li osoba koja je popunjavala upitnik što je ekspertni sustav i koriste li ga, postoji li preventivno održavanje, za koje razdoblje te mišljenje o tome koji je način održavanja isplativiji – preventivni ili reaktivni.

2. Opći podatci o kanalizacijskom sustavu

Traženi su podatci o vrsti kanalizacije (mješovita, razdjelna, oborinska i sl.), duljinama pojedinih dijelova, ukupnoj duljini kanalizacijskog sustava, ukupnom broju priključaka na kanalizacijski sustav, broju crpnih stanica, pročišćavaju li se vode ili se samo ispuštaju u prijemnik, broju uređaja za pročišćavanje otpadnih voda, priključenosti stanovništva na kanalizacijski sustav te starosti kanalizacijskog sustava.

3. Količine odvođenja (ispuštanja) otpadnih voda

Tu su traženi podatci o količinama odvođenja otpadnih voda za promatrane godine.

4. Podatci o promjerima, vrstama i duljinama cijevi

U ovom dijelu upitnika prikupljani su podatci o vrsti korištenih cijevi u kanalizacijskom sustavu, dubinama postavljanja i duljinama korištenih cijevi. Tu je važno za naglasiti da jako malo anketiranih poduzeća (a općenito i drugih koji nisu ispitivani) ima kanalizacijski sustav prikazan u GIS-u tako da je te podatke teško ili nemoguće dobiti.

5. Podatci o održavanju kanalizacijskog sustava

U ovom dijelu upitnika, za koji se može reći da je jako važan, tražili su se podatci o troškovima održavanja za pojedinu promatranu godinu, zatim broj kvarova, troškovi održavanja crpnih stanica, troškovi čišćenja kanalizacijskih cijevi. Također, ovaj dio, gdje se traže podaci o troškovima održavanja kanalizacijskog sustava, anketiranim poduzećima bio je najteži za ispuniti. Čim se radi o troškovima, to se smatra poslovnom tajnom, ali i neka poduzeća koja bi željela ispuniti upitnik nisu to mogla učiniti jer ne vode odvojene financije za održavanje, a obično poduzeća koja upravljaju kanalizacijskom sustavom istovremeno upravljaju i vodoopskrbom što još više otežava razdiobu troškova na samo troškove održavanja kanalizacijskog sustava te daljnju podjelu troškova unutar toga. Odabir poduzeća koja se bave odvodnjom, odnosno upravljanjem kanalizacijskim sustavom napravljen je na način da su se na karti Republike Hrvatske birali manji, srednji i veći gradovi ili naselja te se nakon toga pristupilo traženju poduzeća za odvodnju na području tog grada. Nastojalo se da gradovi različite veličine na području cijele RH budu obuhvaćeni, a samim time što su gradovi manji ili veći, to su i kanalizacijski sustavi isto tako manji ili veći. Također, u obzir se uzimala i kontinentalna i primorska Hrvatska.

Kako bi se olakšalo prikupljanje podataka o troškovima održavanja kanalizacijskog sustava, razvijena je struktura troškova i određenih podataka o funkcioniranju kanalizacijskog sustava

prikazana u tablici 4.1. Kada bi se prema dolje navedenoj strukturi prikupljali podatci o troškovima održavanja kanalizacijskog sustava, isto bi omogućilo praćenje troškova na godišnjoj razini, kao i razvoj točnijih modela za procjenu troškova održavanja kanalizacijskog sustava.

Tablica 4.1. Razvijena struktura podataka i troškova održavanja kanalizacijskog sustava

R. broj	Podatak
1.	Troškovi održavanja kanal. sustava za pojedinu godinu [kn], od toga:
2.	a) strojni rad
3.	b) ljudski rad
4.	c) materijal
5.	d) ostalo
6.	Broj kvarova u pojedinoj godini
7.	Najučestaliji kvarovi
8.	Troškovi rada (el. energije) crpnih stanica [kn]
9.	Troškovi održavanja crpnih stanica [kn]
10.	Troškovi CCTV snimanja [kn]
11.	Koliko km je snimljeno CCTV-om
12.	Troškovi čišćenja (ispiranja) kanal. sustava [kn]
13.	Koliko km je očišćeno (isprano)
14.	Troškovi sanacije bez iskopa [kn]
15.	Koliko km je sanirano bez iskopa
16.	Gorivo utrošeno na održavanje [kn] ili [l]

Istraživanje pomoću upitnika, odnosno slanje istih poduzećima u Republici Hrvatskoj rađeno je tijekom 2019. godine tako da je zadnja godina s potpunim podacima bila 2018. godina. U 2018. godini u Republici Hrvatskoj bilo je 134 poduzeća čija je djelatnost Skupljanje, pročišćavanje i opskrba vodom (prema NKD-u 2007. E36.00), a 67 poduzeća čija je djelatnost Uklanjanje otpadnih voda (prema NKD-u 2007. E37.00) [224]. Prema tome, kako je upitnik poslan 68 poduzeća, a ukupno je bilo 134 poduzeća, proizlazi da je upitnik poslan 50,74 % poduzeća u Republici Hrvatskoj koja su zadužena za javnu odvodnju i opskrbu vodom.

U Tablici 4.2. prikazan je popis poduzeća kojima su poslani upitnici.


Tablica 4.2. Popis poduzeća kojima su poslani upitnici na području Republike Hrvatske

R. br.	Mjesto	Naziv
1.	Beli Manastir	Baranjski vodovod d.o.o.
2.	Belišće	Hidrobel d.o.o.
3.	Blato	VODOVOD d.o.o. Blato
4.	Buzet	Istarski vodovod d.o.o., 6. Maj d.o.o.
5.	Čakovec	MEĐIMURSKE VODE d.o.o.
6.	Čazma	Komunalije - vodovod d.o.o. Čazma
7.	Darda	Vodoopskrba d.o.o.
8.	Daruvar	Darkom vodoopskrba i odvodnja d.o.o.
9.	Delnice	Komunalac - VIO d.o.o. Delnice
10.	Donji Miholjac	Miholjački vodovod d.o.o.
11.	Dubrovnik	VODOVOD DUBROVNIK d.o.o.
12.	Duga Resa	Komunalno Duga Resa d.o.o.
13.	Đakovo	Đakovački vodovod d.o.o.
14.	Đurđevac	KOMUNALIJE d.o.o.
15.	Glina	Vodovod Glina d.o.o.
16.	Gospić	USLUGA d.o.o. za vodoopskrbu i odvodnju
17.	Grubišno Polje	Vodovod Grubišno Polje d.o.o.; Komunalac d.o.o.
18.	Hrvatska Kostajnica	Komunalac d.o.o.
19.	Imotski	VODOVOD IMOTSKE KRAJINE d.o.o.
20.	Ivanec	Ivkom-vode d.o.o.
21.	Ivanić-Grad	Vodoopskrba i odvodnja Zagrebačke županije d.o.o.
22.	Jastrebarsko	Vode Jastrebarsko d.o.o.
23.	Karlovac	Vodovod i kanalizacija d.o.o.
24.	Knin	Komunalno poduzeće d.o.o.
25.	Koprivnica	Koprivničke vode d.o.o.
26.	Krapina	Krakom - vodoopskrba i odvodnja d.o.o.
27.	Križevci	KOMUNALNO PODUZEĆE d.o.o. Križevci
28.	Krk	PONIKVE VODA d.o.o.
29.	Kutina	Moslavina d.o.o.
30.	Labin	VODOVOD LABIN d.o.o.
31.	Makarska	Vodovod Makarska d.o.o.
32.	Metković	Metković d.o.o.
33.	Našice	NAŠIČKI VODOVOD d.o.o.
34.	Nova Gradiška	Vodovod zapadne Slavonije d.o.o.
35.	Novi Vinodolski	KTD Vodovod Žrnovnica d.o.o.
36.	Novska	Vodovod Novska d.o.o.

37.	Ogulin	Vodovod i kanalizacija d.o.o.
38.	Osijek	Vodovod Osijek d.o.o.
39.	Otočac	Komunalac d.o.o. Otočac
40.	Ozalj	Komunalno Ozalj d.o.o.
41.	Pag	Komunalno društvo Pag d.o.o.
42.	Pakrac	VODE LIPIK d.o.o.
43.	Petrinja	PRIVREDA d.o.o.
44.	Pitomača	Vodakom d.o.o.
45.	Ploče	JU IZVOR PLOČE
46.	Poreč	ODVODNJA POREČ d.o.o.
47.	Požega	Tekija d.o.o.
48.	Pregrada	Vodoopskrba i odvodnja Pregrada d.o.o.
49.	Pula	Pragrande d.o.o.
50.	Rijeka	Komunalno društvo VODOVOD I KANALIZACIJA d.o.o.
51.	Rovinj	Odvodnja Rovinj - Rovigno d.o.o.
52.	Sinj	Vodovod i odvodnja Cetinske Krajine d.o.o.
53.	Sisak	Sisački vodovod d.o.o.
54.	Slatina	KOMRAD d.o.o.
55.	Slavonski Brod	Vodovod d.o.o.
56.	Split	Vodovod i kanalizacija d.o.o.
57.	Šibenik	Vodovod i odvodnja d.o.o.
58.	Valpovo	DVORAC d.o.o.
59.	Varaždin	Varkom d.d.
60.	Vinkovci	Vinkovački vodovod i kanalizacija d.o.o.
61.	Virovitica	Virkom d.o.o.
62.	Vrbovsko	VODE VRBOVSKO d.o.o.
63.	Vukovar	Vodovod grada Vukovara d.o.o.
64.	Zabok	Zagorski vodovod d.o.o.
65.	Zadar	Odvodnja d.o.o. Zadar
66.	Zagreb	Vodoopskrba i odvodnja d.o.o.
67.	Zaprešić	Vodoopskrba i odvodnja Zaprešić d.o.o.
68.	Županja	Komunalac d.o.o.

4.2. Odaziv na upitnik i prikupljeni podatci


Podatci o karakteristikama kanalizacijskih sustava, količini odvođenja otpadnih voda i troškovima održavanja kanalizacijskih sustava prikupljeni su tijekom 2019. godine pomoću upitnika predstavljenog u prethodnom poglavlju. Odaziv na anketu prikazan je na slici 4.1.



Slika 4.1. Odaziv na zamolbu i upitnik

Na slici 4.1. prikazan je odaziv na poslanu zamolbu i upitnik. Od navedenog udjela dio podataka koji su dobiveni nisu bili upotrebljivi budući da su neki ispunili upitnik, ali količina podataka nije bila dovoljna za obradu, neka poduzeća su javila da uopće nemaju kanalizacijski sustav (tj. imaju samo vodoopskrbni sustav), neka nisu željela ustupiti podatke, neka su uputila da se javi drugim poduzećima. Udio poduzeća koja su odgovorila na zamolbu je 39,70 % (27 poduzeća), dok 60,30 % (41 poduzeće) nije odgovorilo na zamolbu.

Nakon toga, kada se sve navedeno uvažilo, stvarni odaziv na anketu, odnosno ona poduzeća koja su dostavila ispunjene upitnike prikazan je na slici 4.2. Vidljivo je kako je 77,78 %, odnosno 21 onih poduzeća koja su odgovorila na zamolbu ispunilo upitnik, dok 22,22 %, odnosno 6 poduzeća koja su odgovorila na zamolbu nije ispunilo upitnik iz različitih razloga (ne žele dati podatke, ne raspolažu s tim podacima, uopće nemaju kanalizacijski sustav, nego samo vodoopskrbni sustav).




Slika 4.2. Udio poduzeća koja su dostavila ispunjene upitnike

Nakon početne analize dostavljenih ispunjenih upitnika pojavilo se nekoliko problema. Jedan od problema je taj što su poduzeća obično dostavila ispunjena četiri dijela upitnika, dok onaj dio koji prikazuje troškove održavanja kanalizacijskog sustava nije bio ispunjen. Jasno je da takvi upitnici nisu bili prikladni za daljnju upotrebu i obradu. Također, bilo je još problema u slučaju kada su neki određeni neophodni podatci (npr. količine otpadnih voda, duljina kanalizacijske mreže) nedostajali te su takvi upitnici također bili izuzeti iz daljnje analize i obrade.


Slijedom svega prethodno navedenoga, udio ispunjenih upitnika koji su bili valjani za daljnju analizu i obradu prikazan je na slici 4.3. Od svih dostavljenih ispunjenih upitnika 57,14 % (12) poduzeća je dostavilo potpune podatke, dok je 42,86 % (9) od ispunjenih podataka bilo nepotpuno te se nije moglo koristiti u daljnjoj analizi.

Od 68 kontaktiranih poduzeća u Republici Hrvatskoj, njih 12 je dostavilo potpune podatke koji su korišteni u daljnjoj analizi.



Slika 4.3. Struktura valjanosti dostavljenih podataka

Troškovi održavanja kanalizacijskog sustava prikupljani su na godišnjoj bazi. Udio kanalizacijskih sustava prema broju godina (referentnom razdoblju) za koji su prikupljani troškovi održavanja prikazan je na slici 4.4. Razdoblje za koje su dostavljeni podatci kreće se od 2 do 10 godina.



Slika 4.4. Struktura podataka prema broju godina za koji su dostavljeni podatci

Najveći dio podataka dostavljen je za razdoblje od 10 godina (25 %, tj. 3 poduzeća), zatim slijedi razdoblje od 3, 5 i 6 godina s jednakim udjelima od po 16,67 %, tj. po 2 poduzeća. Za razdoblja od 2, 8 i 9 godina dostavljeno je 8,33 % podataka za svaka od navedena tri razdoblja. Prema tome, kako je 25 % podataka dostavljeno za maksimalno razdoblje koje se tražilo u upitniku (10 godina), to će omogućiti izradu modela koji će procjenjivati troškove održavanja kanalizacijskih sustava za razdoblje od 10 godina.

Prema vrijednostima određenih karakteristika kanalizacijskih sustava za 2018. godinu (zadnja godina za koju su dostavljeni podatci o kanalizacijskim sustavima pomoću upitnika) kao što su: ukupna duljina kanalizacijske mreže, broj kanalizacijskih priključaka, broj UPOV-a i količina odvođenja otpadnih voda moguće je također uočiti koliki je obuhvat provedenog istraživanja. Podatci o navedene četiri karakteristike za 2018. godinu preuzeti su sa službene internetske stranice Državnog zavoda za statistiku Republike Hrvatske [239], [240]. Podatci o provedenom istraživanju dani su u tablici 4.3.

Tablica 4.3. Podatci o obuhvatu provedenog istraživanja

Karakteristika kanal. sustava	Ukupno u 2018. godini [239], [240]	Ukupno za dostavljene potpune upitnike	Udio
Ukupna duljina kanalizacijske mreže [km]	12.529	2668,51	21,29 %
Ukupan broj priključaka na kanalizaciju [kom]	587.922	132.240	22,49 %
Broj UPOV-a [kom]	151	31	17,82 %
Količina odvođenja otpadnih voda [m ³]	335.807.000	38.304.853,15	11,41 %

Iz svih dostavljenih podataka, analizom dosadašnjih istraživanja, pregledom i analizom literature definirane su neovisne varijable koje se mogu smatrati važne za definiranje modela procjene troškova održavanja kanalizacijskog sustava. Iz upitnika koji je poslan poduzećima definirane su varijable. Popis neovisnih varijabli dan je u tablici 4.4.

Tablica 4.4. Popis mogućih neovisnih varijabli modela procjena troškova održavanja kanalizacijskog sustava

Broj varijable	Naziv varijable	Mjerna jedinica	Vrsta varijable
1	Broj zaposlenih na poslovima održavanja kanalizacijskog sustava	kom	diskretna numerička
2	Ukupna duljina kanalizacijske mreže	km	neprekidna numerička
3	Ukupan broj priključaka na kanalizaciju	kom	diskretna numerička
4	Broj crpnih stanica	kom	diskretna numerička
5	Broj uređaja za pročišćavanje otpadnih voda	kom	diskretna numerička
6	Starost kanalizacijskog sustava	god	neprekidna numerička
7	Prosječna godišnja količina odvođenja otpadnih voda	m ³	neprekidna numerička
8	Prosječni godišnji troškovi održavanja kanalizacijskog sustava	kn	neprekidna numerička
9	Položaj (kopno/more)	-	kvalitativna

Iz svih dobivenih valjano i potpuno ispunjenih upitnika napravljena je baza podataka koja je korištena za statističku obradu.

U tablici 4.5. prikazane su vrijednosti ovisnih varijabli od kojih će se neke koristiti u izradi modela procjene troškova održavanja, tj. prosječni godišnji nominalni troškovi održavanja kanalizacijskih sustava, odnosno prosječna godišnja sadašnja vrijednost troškova održavanja.

Za pojedini kanalizacijski sustav izračunata je ukupna sadašnja vrijednost troškova održavanja kanalizacijskog sustava za referentno razdoblje, prosječna godišnja sadašnja vrijednost troškova održavanja te prosječni godišnji nominalni troškovi održavanja. Ukupna sadašnja vrijednost troškova održavanja dobivena je tako da su troškovi održavanja iz prošlosti svedeni na sadašnju vrijednost prema literaturi [242]–[246], dok je za diskontnu stopu uzeta vrijednost od 3 % za prosinac 2021. godine prema [247], [248]. Prosječna godišnja sadašnja vrijednost troškova dobivena je tako da je ukupna sadašnja vrijednost troškova održavanja za referentno razdoblje podijeljena s brojem godina za koje su dostavljeni troškovi (tj. s referentnim razdobljem). Svođenje troškova održavanja na sadašnju vrijednost napravljeno je iz razloga što se vrijednost novca mijenja tijekom vremena [249].

Ostale neovisne varijable kao što su ukupna duljina kanalizacijske mreže, ukupan broj priključaka na kanalizaciju i broj crpnih stanica nisu se mijenjale tijekom referentnog razdoblja, a koji princip su usvojili autori Krstić [103] i Gudac Hodanić [123] u svojim doktorskim disertacijama.

Od dolje navedenih 12 poduzeća u tablici 4.5., od kojih su dobiveni dostatno ispunjeni upitnici za daljnju analizu, njih osam je iz kontinentalne Hrvatske, dok je četiri iz primorske Hrvatske.

Tablica 4.5. Ukupna sadašnja vrijednost troškova održavanja, prosječna godišnja sadašnja vrijednost troškova održavanja te prosječni godišnji nominalni troškovi održavanja


Broj kanalizacijskog sustava	Ukupna sadašnja vrijednost troškova održavanja za ref. razdoblje [kn]	Prosječna godišnja sadašnja vrijednost troškova održavanja [kn]	Prosječni godišnji nominalni troškovi održavanja [kn]
1	3.934.175,88	786.835,18	667.876,06
2	41.376.910,31	5.172.113,79	4.190.500,00
3	6.055.996,73	1.211.199,35	1.018.694,20
4	25.715.237,71	2.857.248,63	2.301.466,22
5	1.029.564,06	102.956,41	84.000,00
6	1.084.807,67	180.801,28	149.166,67
7	11.423,91	5.711,96	5.000,00
8	13.627.490,58	1.362.749,06	1.109.583,88
9	257.659,11	85.886,37	73.692,00
10	88.381,90	14.730,32	12.166,67
11	1.706.412,30	170.461,23	132.675,41
12	134.405,26	44.801,75	39.199,30

4.3. Analiza podataka i odgovora iz upitnika


U upitniku se tražilo odgovore na određena pitanja, kao što je broj zaposlenih na poslovima održavanja kanalizacijskog sustava, ukupna duljina kanalizacijskog sustava i ukupan broj priključaka na kanalizaciju, a svi odgovori na navedena pitanja su u brojevnom obliku. U nastavku su prethodno navedene karakteristike prikazane na slikama za analiziranih 12 poduzeća koja su dostavila ispunjene upitnike.

Na slici 4.5. prikazana je duljina kanalizacijskog sustava i broj zaposlenih na poslovima održavanja kanalizacijskog sustava za analiziranih 12 sustava. Vidljivo je da je u najvećoj mjeri isti trend kretanja duljine kanalizacijskog sustava i broj zaposlenih na poslovima održavanja

kanalizacijskog sustava, odnosno da što je veća duljina, to je zaposlenih više; naravno, uz određena odstupanja i iznimke.




Slika 4.5. Prikaz duljine kanal. sustava i broja zaposlenih na poslovima održavanja kanal. sustava



Slika 4.6. Prikaz duljine kanal. sustava i broj priključaka na kanal. sustav

Na slici 4.6. prikazano je kako u najvećoj mjeri povećanje duljine kanalizacijskog sustava prati i povećanje broja priključaka za analiziranih 12 kanalizacijskih sustava. Također se vidi da je kod određenih kanalizacijskih sustava prisutna manja priključenost na iste, u usporedbi s analiziranim kanalizacijskim sustavima.



Slika 4.7. Prikaz duljine kanal. sustava i prosječne godišnje količine odvođenja otpadnih voda

Na slici 4.7. prikazano je kretanje duljine kanalizacijskog sustava i prosječne godišnje količine odvođenja otpadnih voda. Vidljivo je kako, u najvećoj mjeri, veća duljina kanalizacijskog sustava znači i veću količinu odvođenja otpadnih voda. Također, treba imati na umu da su to prosječne godišnje količine vode tako da je u određenoj godini ta količina otpadne vode veća ili manja od ove prosječne, ali i da kod nekih kanalizacijskih sustava ima manje, a kod nekih više industrije koje su veći proizvođači otpadne vode nego stambene zgrade.

Tri pitanja koja su zahtijevala odgovor s „da“, „ne“, „ne znam“, a koja je važno prikazati budući da govore o razmišljanju održavatelja, praksi održavanja, tj. uvažava li se preventivno ili reaktivno održavanje, su sljedeća:


1. Temelji li se održavanje kanalizacijskog sustava samo na popravljanju kvarova i nedostataka?
2. Postoji li preventivna strategija održavanja kanalizacijskog sustava za određeno razdoblje?
3. Mislite li da je isplativije preventivno održavanje ili reaktivno i ukratko objasnite zašto.

U slučaju potvrdnog odgovora na prvo pitanje da se održavanje kanalizacijskog sustava temelji samo na popravljaju kvarova i nedostataka, vrijedi to da se radi reaktivno održavanje, dok se preventivno zanemaruje. Drugo pitanje govori o tome postoji li preventivna strategija održavanja.

Treće pitanje je važno iz razloga što se želi vidjeti razmišljanje osoba koje su zadužene za upravljanje i održavanje kanalizacijskog sustava budući da je u prethodnom dijelu rada pokazano kako je preventivni način održavanja troškovni učinkovitiji, i bolji u svakom slučaju.


Broj analiziranih upitnika na ova tri pitanja, odnosno odgovora je 19 budući da je toliko odgovora dano za sva tri pitanja.

Na slici 4.8. dan je udio odgovora na prvo pitanje: „Temelji li se održavanje kanalizacijskog sustava samo na popravljaju kvarova i nedostataka?“ Udio onih odgovora gdje se održavanje kanalizacijskog sustava temelji samo na popravljaju kvarova i nedostataka je 58 % (11 odgovora), dok je onih koji su odgovorili drugačije 42 % (osam odgovora).




Slika 4.8. Prikaz odgovora na pitanje: „Temelji li se održavanje kanal. sustava samo na popravljaju kvarova i nedostataka?“

Na slici 4.9. dan je udio odgovora na drugo pitanje: „Postoji li preventivna strategija održavanja kanalizacijskog sustava za određeno razdoblje?“ Udio odgovora gdje se održavanje kanalizacijskog sustava temelji samo na popravljaju kvarova i nedostataka je 68 % (13 odgovora), dok je onih koji su odgovorili da ne postoji preventivna strategija održavanja 32 % (šest odgovora).



Slika 4.9. Prikaz odgovora na pitanje: „Postoji li preventivna strategija održavanja kanalizacijskog sustava za određeno razdoblje?“

Na slici 4.10. dan je udio odgovora na treće pitanje: „Mislite li da je isplativije preventivno održavanje ili reaktivno i ukratko objasnite zašto.“ Udio onih koji misle da je preventivno održavanje isplativije je 79 % (15 odgovora), onih koji misle da je reaktivno održavanje isplativije je 11 % (dva odgovora), 5 % (jedan odgovor) smatra da su oba načina isplativa te 5 % (jedan odgovor) ne zna.



Slika 4.10. Prikaz odgovora na pitanje: „Mislite li da je isplativije preventivno ili reaktivno održavanje...?“

Analizirajući odgovor na prvo pitanje, uočava se da je trenutna praksa kod održavanja kanalizacijskih sustava reaktivno održavanje, ali gledajući odgovor na drugo pitanje, može se zaključiti kako ipak postoji određena preventivna strategija održavanja kanalizacijskog sustava, ali je vjerojatno upitno u kojoj mjeri se ona provodi. Odgovor na treće pitanje je možda i najzanimljiviji budući da se uočava kako osobe zadužene za upravljanje, odnosno održavanje kanalizacijskog sustava smatraju da je preventivno održavanje isplativije te su svjesni toga, ali je iz prvog pitanja vidljivo kako se preventivno održavanje provodi u manjoj mjeri nego reaktivno održavanje koje se temelji na popravljaju kvarova i nedostataka u trenu kada se oni pojave.

4.4. Statistička obrada podataka

4.4.1. Osnovna statistička obrada podataka

U osnovnoj statističkoj obradi podataka napravljena je obrada prikupljenih podataka. U tablici 4.6. prikazana je aritmetička sredina, minimum, maksimum i standardna devijacija svih promatranih varijabli za analiziranih 12 kanalizacijskih sustava, odnosno 12 poduzeća koja su odgovorila na upitnike.

Tablica 4.6. Deskriptivna statistika seta podataka

Broj varijable	Naziv varijable	Aritmetička sredina	Minimum	Maksimum	Standardna devijacija
1	Broj zaposlenih na poslovima održavanja kanalizacijskog sustava	14	2	32	11
2	Ukupna duljina kanalizacijske mreže	222	5,1	752	225
3	Ukupan broj priključaka na kanalizaciju	11.020	55	30.805	9.921
4	Broj crpnih stanica	36	1	92	33
5	Broj uređaja za pročišćavanje otpadnih voda	3	0	7	2

6	Starost kanalizacijskog sustava	40	5	80	23
7	Prosječna godišnja količina odvođenja otpadnih voda	3.065.013	4.197,33	14.223.945	4.377.845
8	Prosječni nominalni godišnji troškovi održavanja kanalizacijskog sustava	815.335	5.000	4.190.500	1.266.664
9	Prosječna godišnja sadašnja vrijednost troškova održavanja kanalizacijskog sustava	999.633	5.711,96	5.172.114	1.565.204

Kada se pogleda gornja tablica, vidljiva je velika razlika između minimalnih i maksimalnih vrijednosti sljedećih varijabli: ukupne duljine kanalizacijske mreže, ukupnog broja priključaka na kanalizaciju, prosječne starosti kanalizacijskog sustava, prosječne godišnje količine odvođenja otpadnih voda, prosječnih nominalnih godišnjih troškova održavanja kanalizacijskog sustava te prosječne godišnje sadašnje vrijednosti troškova održavanja kanalizacijskog sustava.

Program koji je korišten u obradi podataka je *Statistica*, verzija 14.0.0.15. *Statistica* je sveobuhvatan analitički, istraživački i poslovni alat. To je integrirani sustav koji omogućuje upravljanje podacima, analizu, rudarenje podataka, vizualizacije i razvoj prilagođenih aplikacija koji sadrži širok izbor osnovnih i naprednih analitičkih postupaka za poslovne, podatkovne, znanstvene i inženjerske primjene. *Statistica* ne obuhvaća samo analitičke, grafičke i analitičke postupke te postupke upravljanja bazama podataka, već i opsežnu primjenu specijaliziranih metoda za analizu podataka. Ulazne i izlazne datoteke i grafikoni *Statistice* mogu biti praktički neograničene veličine. Izlazni izvještaji mogu biti u obliku tablica, radnih knjiga, izvješća (uključujući PDF datoteke i Microsoft Office dokumente) i dr. [250].

Osim navedenog programa, korišten je i programski jezik R. To je programski jezik i okruženje za statističke izračune i vizualizaciju. Dostupan je na internetu pod licencom *General Public License* (GPL) tako da se može slobodno koristiti i distribuirati te je otvorenog koda [251]–

[253]. Pojam „okruženje” govori da je to potpuno planiran i koherentni sustav, a ne kao postupno povećani vrlo specifični i nefleksibilni alati, kao što je to često slučaj s drugim softverom za analizu podataka [254]. R pruža širok izbor statističkih metoda za linearno i nelinearno modeliranje, klasične statističke testove, analize vremenskih serija, klasteriranje te je lako proširiv s velikim izborom grafičkih tehnika. Statističari su razvili velik broj specijaliziranih statističkih procedura za širok raspon uporabe putem tzv. pridodanih paketa koji su slobodno dostupni i integrirani direktno sa sustavom R [253].

4.4.2. Odabir statističke metode i varijabli modela

Cilj istraživanja i izrade ove doktorske disertacije je istražiti u kojoj je mjeri moguće prikupiti povijesne podatke o karakteristikama kanalizacijskih sustava te troškovima održavanja istih, opisati postojeće probleme i tehnologije održavanja kanalizacijskih sustava, kao i istražiti mogućnosti stvaranja modela procjene troškova. Većina ciljeva je vezana uz izradu modela procjene troškova održavanja kanalizacijskog sustava te se primjenom takvog modela želi povećati učinkovitost održavanja kanalizacijskih sustava. Kako bi se izradio model procjene troškova održavanja, potrebno je pomoću određenih neovisnih varijabli napraviti model za izračun ovisne varijable – troškova održavanja.

Općenito, regresijska analiza otkriva odnose između zavisne i nezavisne varijable [255]. Podatci se sastoje od neprekidnih numeričkih i diskretnih numeričkih varijabli te s obzirom na navedeno pokušat će se izraditi regresijski model procjene troškova održavanja. Uvijek kada se govori o modeliranju, cilj bilo kojeg modela je da što bolje oponaša ponašanje stvarnog sustava, u ovom slučaju da što bolje oponaša – procjenjuje troškove održavanja. Ta osobina – osobina da model ispravno predviđa buduće stanje sustava, naziva se prediktivna valjanost modela [256]. Zavisna varijabla je ona varijabla koja se prognozira [257], a nezavisna je ona varijabla pomoću koje se prognozira.

Općenito, modeli se koriste iz nekoliko razloga:


- objašnjavanje pojava koje se javljaju u sustavu
- izrada predviđanja o budućem stanju sustava
- procjena ključnih faktora koji utječu na pojave u sustavu
- identificiranje graničnih stanja u sustavu koji mogu rezultirati najgorim scenarijima ili minimizirati troškove
- analiza kompromisa kao pomoć odlučivanju [258], [259] i

- značajno smanjenje vremena za analizu određene pojave [260].

Regresijski modeli mogu se koristiti za predviđanje vrijednosti zavisne varijable, naravno ako se raspoložuje vrijednošću nezavisne varijable [261]. Cilj izgradnje i uporabe modela je napraviti jednostavan model koji će biti lagano koristiti, a koji će davati dovoljno blisku aproksimaciju složene stvarnosti. Model se mora moći lagano interpretirati, ali ne smije biti toliko jednostavan da zanemari važne utjecaje. Problem izgradnje statističkog modela ovisan je o promatranom problemu. Četiri faze izgradnje modela prikazane su na slici 4.11.

Uvijek na umu treba imati da je model idealizirani opis stvarnosti što znači da je stvarnost uzeta s obzirom na relevantne činjenice koje se odnose na promatrani problem [262].

Kod izgradnje modela koraci kojima se vodilo prikazani su na slici 4.11. Odredilo se zašto će se model koristiti, zatim su se odredili koeficijenti uz nezavisne varijable, model je validiran na testnom uzorku te je, na samom kraju, dana interpretacija i zaključci, kao i prednosti i ograničenja kod uporabe takvog modela.



Slika 4.11. Koraci izgradnje statističkog modela [261]


Kod izrade modela jako je važno imati znanje o specifičnom području za koje se radi model.

Regresijski modeli koriste se iz nekoliko razloga, a to su:

- Deskriptivnost – govori o jakosti veze između ulaznih varijabli i izlaznih varijabli.

- Usklađivanje – usklađivanje prema nezavisnim varijablama koje su u povezanosti sa zavisnim (izlaznim) varijablama.
- Predviđanje – utvrđivanje rizičnih faktora koji utječu na izlazne (ovisne) varijable.
- Cijena – nekada prikupljanje ovisnih varijabli može biti veoma skupo, a prikupljanje neovisnih varijabli ne.
- Vrijeme – budući da se izlazne (ovisne) varijable javljaju u budućnosti, teško je znati vrijednosti tih varijabli u sadašnjosti, ali korištenjem regresijske analize one postaju dostupne odmah [263], [264].
- Objašnjenje – regresijski model procjenjuje utjecaj nezavisnih varijabli na zavisnu varijablu, odnosno rezultat [265].
- Podešavanje i kontrola procesa [266].

Svrha modela je uočiti veze između dviju ili više promatranih varijabli što se može ustanoviti jednostavnim uspoređivanjem članova niza. Veza među pojavama postoji ako porast jedne varijable prati porast druge, i obratno. U prvom je slučaju smjer veze među pojavama ili varijablama pozitivan, a u drugom je slučaju smjer veze negativan [267]. Statistički gledano, ako je kovarijanca veća od nule, onda su varijable pozitivno korelirane te vrijedi da malim vrijednostima jedne slučajne varijable odgovaraju pretežito male vrijednosti druge varijable, a velikim vrijednostima jedne varijable odgovaraju velike vrijednosti druge varijable. Ako je kovarijanca manja od nule, onda su varijable negativno korelirane. U tom slučaju vrijedi da malim vrijednostima jedne slučajne varijable pretežito odgovaraju velike vrijednosti druge varijable, a velikim vrijednostima jedne varijable odgovaraju male vrijednosti druge varijable [256]. Kod analiziranja prikupljenih podataka promatrala se korelacija varijabli, a što je općenito prikazano na slici 4.12.



Slika 4.12. Korelacija slučajnih varijabli [256]

Na slici 4.12. dolje desno je vidljivo nepostojanje korelacije varijabli, te kod varijabli analiziranih u radu gdje se isto pojavilo na dijagramu raspršenosti iste su izuzete iz daljnje analize. Tijekom analiziranja varijabli i njihovih međusobnih zavisnosti napravljeni su dijagrami raspršenosti te je tako preliminarno uočeno postoji li korelacija varijabli i u kojoj mjeri.

O povezanosti među varijablama govori *Pearsonov* koeficijent korelacije (r). Veličina koeficijenta korelacije može biti između $+1$ i -1 [268]–[275]. Korelacija u statističkoj analizi označava povezanost jedne ili više (nezavisnih) varijabli s jednom zavisnom varijablom [276]. Koeficijent korelacije najčešće je korištena mjera za opisivanje povezanosti varijabli. Na osnovi veličine koeficijenta korelacije nije moguće zaključivati o povezanosti i uzročnosti među promatranim varijablama [268], [270], [271]. Jakost koeficijenta korelacije te tumačenje dano je u tablici 4.7. Kod interpretacije korelacije između varijabli korištena je prethodno navedena tablica.

Tablica 4.7. Vrijednosti koeficijenta korelacije i njihova tumačenja [271]

r		Opis povezanosti
od - do		
-1		Potpuna negativna korelacija
-1	-0,7	Snažna negativna korelacija
-0,7	-0,3	Umjerena negativna korelacija
-0,3	+0,3	Slaba korelacija
0		Bez korelacije
+0,3	+0,7	Umjerena pozitivna korelacija
+0,7	+1	Snažna pozitivna korelacija
+1		Potpuna pozitivna korelacija

Vrijednosti dane u tablici ne smiju se gledati strogo u smislu tumačenja budući da gore dane vrijednosti predstavljaju najčešće uvriježene granice za tumačenje koeficijenta korelacije [271]. Razina značajnosti je rizik koji se preuzima kada se tvrdi da je nešto statistički značajno, tj. da nije slučajno [268].

Kako bi se ustanovilo je li dobiveni koeficijent korelacije statistički značajan, potrebno je izračunati p vrijednost. Značajnost povezanosti ovisit će o vrijednosti koeficijenta korelacije i veličini uzorka koji je mjeren [270]. Vrijednost p , odnosno izračunata vjerojatnost izražava vjerojatnost nekog rezultata. Pomoću te vrijednosti nastoji se utvrditi mogućnost da je dobiveni

rezultat posljedica slučajnosti, a ne stvarne razlike između mjerenih varijabli [277]. Uobičajeno se za prag statističke značajnosti uzima vrijednost $p < 0,05$ [278]–[280]. U slučaju $p < 0,05$ to bi značilo da postoji manje od 5 % mogućnosti da se mjerenjem utvrdi određena razlika između mjerenih varijabli pri istinitoj nultoj hipotezi, odnosno kad navedena razlika ne postoji [277], što onda posredno znači da je vjerojatnost da je neki drugi mjereni podatak u granicama prije mjerenih podataka 95 %.

Izraz razina značajnosti (α , alfa) koristi se za upućivanje na unaprijed odabranu vjerojatnost, a izraz „p vrijednost” upotrebljava se za označavanje vjerojatnosti koja se izračuna nakon određenog ispitivanja. Izbor razine važnosti na kojoj se odbacuje nulta hipoteza je proizvoljan. Uobičajeno se koriste razine 5 %, 1 % i 0,1 % ($p < 0,05$, 0,01 i 0,001). Međutim, ovi brojevi mogu dati lažan osjećaj sigurnosti [279]. U tablici 4.8. dane su najčešće razine značajnosti. Navedene razine značajnosti korištene su i kod interpretacije dobivenih rezultata u ovome radu.

Tablica 4.8. Razine statističke značajnosti [279], [281]

p vrijednost	Uobičajeni zapis	Značenje
$p > 0,05$	$p > .05$	Ne postoji statistička značajnost.
$p < 0,05$	$p < .05$	Statistički značajna razlika.
$p < 0,01$	$p < .01$	Veoma statistički značajna razlika.
$p < 0,001$	$p < .001$	Visoko statistički značajna razlika.

Međutim, samo zato što je p vrijednost $< 0,05$ ili bilo koje druge određene granice, ne bi se trebalo zaključiti da je postavljena hipoteza točna, kao i u slučaju ako je p vrijednost $> 0,05$ da je hipoteza netočna. U biti, označavanje značajnosti daje lažni osjećaj pouzdanosti u pronalazak otkrića u populaciji, dok odbacivanje značajnosti daje lažni osjećaj i dokaz da otkriće na postoji [280]. Zato, p vrijednost treba navesti, ali pri svakom odlučivanju koristiti zdravi razum i znanje onoga koji odlučuje o značajnosti.

Regresijska analiza je proces ugađanja funkcije u djelomičan skup podataka. Linearna regresija je ugađanje podataka s linearnim funkcijama. Navedeno se radi pomoću metode najmanjih kvadrata [282]. Pravac linearnog trenda koji se polaže između skupa točaka (originalnih) podataka metodom najmanjih kvadrata treba smjestiti tako da zbroj odstupanja originalnih vrijednosti trenda bude jednak nula i da zbroj kvadrata tih odstupanja bude minimalan [283]. Pravac najmanjih kvadrata naziva se još i regresijski pravac [282] tako da odatle dolazi naziv regresija.

Kod prognoziranja se mora biti svjestan da prognoza koja se izvodi pomoću regresijskog pravca ne može biti sasvim točna, štoviše ona će biti to manje točna što je niža korelacija između obje pojave tako da su individualni rezultati jako raspršeni oko regresijskog pravca [269].

Dobar model, odnosno model koji se može učinkovito i jednostavno rabiti, treba sadržavati:

- Izraz (formula) treba koristiti mjerljive ulazne podatke koje treba jednostavno moći dobiti.
- Formulu treba biti jednostavno primijeniti.
- Formula treba biti objektivna i primjenjiva na sve institucije koje je koriste.
- Formulu treba moći lako razumjeti.
- Formula treba biti fleksibilna u smislu prilagođavanja promjeni budžeta.
- Formula treba osigurati pouzdane rezultate koji se mogu uspoređivati [284].

Potrebno je pažljivo odabrati varijable koje se koriste u regresijskom modelu jer postoji mogućnost odabira varijabli koje naoko pokazuju povezanost, ali su u stvarnosti i praktičnom smislu u potpunosti nepovezane. Također, regresijska povezanost valjana je samo za vrijednosti neovisne varijable koja se kreće u rasponu originalnih podataka [285].

Višestruki linearni regresijski model je generalizacija jednostavne linearne regresije tako da se pojavljuje više neovisnih varijabli, umjesto jedne koja se javlja u jednostavnoj linearnoj regresiji. Cilj višestruke linearne regresije je objasniti i kvantificirati utjecaj nekoliko neovisnih varijabli na jednu ili više ovisnih varijabli. Model višestruke linearne regresije glasi [251], [265], [286], [287]:

$$y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (4.1)$$

Gdje su:

- Y – zavisna varijabla
- $X_1, X_2, \dots, X_n$ – nezavisne varijable
- $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ – regresijski koeficijenti (konstante)
- ε – slučajna pogreška [286].

Varijabla ε je slučajna varijabla koja se naziva greška relacije te modelu daje statistički (stohastički) karakter. Ona je nemjerljiva te uključuje i sve ostale faktore (osim varijable X) koji utječu na zavisnu varijablu Y . Izvor slučajnih varijacija posljedica je više faktora kao što

su: utjecaj ostalih varijabli koje utječu na zavisnu varijablu, a nisu uključene u model, utjecaj pogrešaka pri mjerenju vrijednosti zavisne varijable, nepredvidivih ekonomskih ili prirodnih utjecaja na zavisnu varijablu i sl. [288]. Regresijski su modeli široko upotrebljavani u procjeni troškova. Učinkoviti su zbog dobro definiranog matematičkog pristupa, kao i mogućnosti objašnjenja veza između nezavisnih i zavisnih varijabli te veličini i jakosti tog međusobnog utjecaja [289]. Zato se, ali i zbog svih prethodno navedenih razloga, u ovom doktorskom radu odlučilo za izradu regresijskog modela procjene troškova održavanja.

Kada se razmatra točnost modela, jedan od dva najčešće korištena pokazatelja je koeficijent determinacije (R^2) [290]. Koeficijent determinacije R^2 govori koliki dio promjena u eksperimentalnim vrijednostima ovisne varijable je objašnjen dobivenim modelom [267], [290], [291]. Kada je vrijednost R^2 blizu jedan, govori da linearan model objašnjava velik dio raspršenosti u eksperimentalnim vrijednostima, tj. samo mali dio je ostao neobjašnjen modelom i treba ga se pripisati slučajnoj pogrešci [290], [291]. Tako, R^2 može poslužiti kao kriterij pri izboru dva modela – model koji ima veći R^2 je bolji [292]. Veličina R^2 može varirati od nule do jedan [261]. Kada bi R^2 bio jednak jedinici, to bi bila idealna veza (regresija) [293].

R^2 se povećava kada se modelu doda nova prediktorska varijabla, čak i ako nova prediktorska varijabla nije povezana s rezultatom [294]. Slijedom toga, ako se uključe sve varijable u model, vrijednost R^2 bi bila bliska 1, ili čak jednaka 1. Kako bi se u obzir uzeo taj učinak, podešeni R^2 sadržava iste informacije kao i uobičajeni R^2 , ali zatim i „kažnjava“ broj varijabli prediktora uključenih u model. Kao rezultat toga, R^2 se povećava s dodavanjem novih prediktorskih varijabli modelu višestruke linearne regresije, ali podešeni R^2 se povećava samo ako je povećanje R^2 veće nego što bi se moglo očekivati samo slučajno. U takvom je modelu podešeni R^2 najrealnija procjena udjela varijacije koji predviđaju prediktorske varijable uključene u model [294]. Kod postavljanja kriterija odabira modela može se koristiti više različitih kriterija koji se mogu napisati, zatim se odrede modeli koji udovoljavaju tim određenim kriterijima te se nakon toga napravi odabir modela. Modeli s velikom vrijednošću R^2 mogu se uključiti na taj popis. Ni jedan od modela neće imati vrijednost koeficijenta determinacije (R^2) kao onaj koji uključuje sve varijable u modelu, ali treba pronaći modele koji s određenim, manjim brojem nezavisnih varijabli imaju koeficijent determinacije što bliži modelu koji sadrži sve neovisne varijable [264]. Kod modela s istim brojem varijabli, bolji je onaj koji ima veći R^2 , a kod modela s različitim brojem varijabli, onaj koji ima veći podešeni R^2 uobičajeno se bira kao bolji [295].

U tablici 4.9. prikazani su koeficijenti korelacije za sve promatrane neovisne varijable i ovisnu varijablu – prosječnu godišnju sadašnju vrijednost troškova održavanja. Kako se vidi u spomenutoj tablici, varijable koje će se uzeti u razmatranje kod izrade modela procjene troškova održavanja su one koje imaju veći koeficijent korelacije i koje su označene crvenom bojom ($p < 0,05$). To su četiri varijable: ukupna duljina kanalizacijske mreže, ukupan broj priključaka na kanalizaciju, broj crpnih stanica te prosječna godišnja količina odvođenja otpadnih voda.

Tablica 4.9. Koeficijenti korelacije neovisnih i ovisnih varijabli

Varijable	Broj zaposlenih	Ukupna duljina	Ukupan broj priključaka	Broj crpnih stanica	Broj UPOV-a	Prosječna starost	Prosječna godišnja količina otpadnih voda	Prosječni godišnji nominalni troškovi održavanja	Prosječna sadašnja vrijednost troškova održavanja
Broj zaposlenih	1,000	0,694	0,878	0,486	0,452	0,327	0,666	0,525	0,520
Ukupna duljina	0,694	1,000	0,922	0,782	0,526	0,474	0,867	0,910	0,908
Ukupan broj priključaka	0,878	0,922	1,000	0,693	0,448	0,462	0,883	0,774	0,771
Broj crpnih stanica	0,486	0,782	0,693	1,000	0,763	0,376	0,472	0,584	0,582
Broj UPOV-a	0,452	0,526	0,448	0,763	1,000	0,522	0,121	0,296	0,288
Prosječna starost	0,327	0,474	0,462	0,376	0,522	1,000	0,235	0,455	0,451
Prosječna god. količina otpadnih voda	0,666	0,867	0,883	0,472	0,121	0,235	1,000	0,792	0,793
Prosječni godišnji nominalni troškovi održavanja	0,525	0,910	0,774	0,584	0,296	0,455	0,792	1,000	1,000
Prosječna sadašnja vrijednost troškova održavanja	0,520	0,908	0,771	0,582	0,288	0,451	0,793	1,000	1,000

Kada se pogleda statistička značajnost određenih varijabli, ona je manja od 0,05 što znači da su navedene četiri varijable statistički značajne.

U Tablici 4.10. dane su p vrijednosti određenih neovisnih varijabli.

Tablica 4.10. Statistički značajne nezavisne varijable za izradu modela procjene troškova održavanja

Naziv varijable	p vrijednost
Ukupna duljina kanalizacijske mreže	0,000044
Ukupan broj priključaka na kanalizaciju	0,003314
Broj crpnih stanica	0,047173
Prosječna godišnja količina odvođenja otpadnih voda	0,002095

Iz tablice se vidi da je neovisna varijabla broj crpnih stanica statistički značajna ($p = 0,0471 < 0,05$), dok su varijable ukupan broj priključaka na kanalizaciju ($p = 0,0033$) i prosječna godišnja količina odvođenja otpadnih voda ($p = 0,0020$) veoma statistički značajne ($p < 0,01$). Varijabla ukupna duljina kanalizacijske mreže ($p = 0,000044$) je visoko statistički značajna jer je $p < 0,001$.

Prema navedene četiri varijable predložit će se nekoliko modela za daljnju razradu. U tablici 4.11., 4.12. i 4.13. dane su vrijednosti koeficijenta determinacije (R^2) i vrijednosti podešenog koeficijenta determinacije (podešeni R^2).

Budući da postoje četiri statistički značajne varijable, u razmatranje su uzeti modeli s najviše tri varijable zbog toga što su određene, dolje navedene, varijable međusobno korelirane te bi procijenjeni regresijski koeficijenti bili tim manje pouzdani što bi bila veća korelacija između dviju ili više nezavisnih varijabli [261]. Modeli koji se razmatraju prikazani su u tablicama 4.11., 4.12. i 4.13.

Tablica 4.11. Prijedlog varijabli modela troškova održavanja s jednom varijablom

Naziv varijable u modelu	R^2	podešeni R^2
Ukupna duljina kanalizacijske mreže	0,8247	0,8072
Ukupan broj priključaka na kanalizaciju	0,5948	0,5542
Broj crpnih stanica	0,3386	0,2724
Prosječna godišnja količina odvođenja otpadnih voda	0,6287	0,5915

Tablica 4.12. Prijedlog varijabli modela procjene troškova održavanja s dvije varijable

Naziv varijabli u modelu	R ²	podešeni R ²
Ukupna duljina kanalizacijske mreže Ukupan broj priključaka na kanalizaciju	0,8549	0,8216
Ukupna duljina kanalizacijske mreže Broj crpnih stanica	0,8673	0,8379
Ukupna duljina kanalizacijske mreže Prosječna godišnja količina odvođenja otpadnih voda	0,8248	0,7859
Ukupan broj priključaka na kanalizaciju Broj crpnih stanica	0,5991	0,5099
Ukupan broj priključaka na kanalizaciju Prosječna godišnja količina odvođenja otpadnih voda	0,6514	0,5739
Broj crpnih stanica Prosječna godišnja količina odvođenja otpadnih voda	0,6839	0,6137

Tablica 4.13. Prijedlog varijabli modela procjene troškova održavanja s tri varijable

Naziv varijabli u modelu	R ²	podešeni R ²
Ukupna duljina kanalizacijske mreže Ukupan broj priključaka na kanalizaciju Broj crpnih stanica	0,9062	0,8710
Ukupan broj priključaka na kanalizaciju Broj crpnih stanica Prosječna godišnja količina odvođenja otpadnih voda	0,6840	0,5655
Ukupna duljina kanalizacijske mreže Broj crpnih stanica Prosječna godišnja količina odvođenja otpadnih voda	0,8955	0,8564
Ukupna duljina kanalizacijske mreže Ukupan broj priključaka na kanalizaciju Prosječna godišnja količina odvođenja otpadnih voda	0,8631	0,8118

Budući da je Chaddockova ljestvica [296], dana u tablici 4.14., pokazatelj koliko dobro vrijednost koeficijenta determinacije R² opisuje model [297], to će se ista koristiti kod početnog vrednovanja modela.

Za daljnje razmatranje i obradu uzet će se modeli koji imaju koeficijent determinacije R² veći od oko 0,64 što bi značilo da postoji čvrsta veza. Naravno, neće svi modeli koji zadovoljavaju taj uvjet biti analizirani budući da takvih prijedloga varijabli modela ima dosta (7), a nije potrebno sve analizirati budući da između određenih nezavisnih varijabli postoji korelacija te

bi u tom slučaju model, odnosno regresijski koeficijenti bili nepouzdana. Između predloženih varijabli modela napraviti će se određena selekcija s obzirom na broj nezavisnih varijabli.

Tablica 4.14. Chaddockova ljestvica [297], [298]

Koeficijent determinacije R^2	Značenje
0,00	Odsutnost veze
0,00 - 0,25	Slaba veza
0,25 - 0,64	Veza srednje jakosti
0,64 - 1,00	Čvrsta veza
1,00	Potpuna veza

Kao kontrola, odnosno za usporedbu je napravljen model koji uključuje četiri statistički značajne varijable te je poznato da se model bolje uklapa u podatke što je složeniji [299], i da je model složeniji kada ima više prediktorskih varijabli u modelu. Vrijednost koeficijenta determinacije $R^2 = 0,9131$, a vrijednost podešenog koeficijenta determinacije iznosi 0,8635 za model koji uključuje četiri statistički značajne varijable te je sada takav model, odnosno prethodno navedene vrijednosti koeficijenta determinacije i podešenog koeficijenta determinacije maksimalna vrijednost koja se može dobiti modelom s četiri prediktorske varijable.

Ako se uključe sve varijable u model, u tom slučaju R^2 iznosi 0,9757, a vrijednost podešenog koeficijenta determinacije iznosi 0,9332. Dodavanjem modelu višestruke regresije dodatnih nezavisnih nesigifikantnih varijabli može se dogoditi, i obično je slučaj, da R^2 drastično poraste [261]. Iz navedenoga se uočava da kada su u model višestruke linearne regresije uključene sve nezavisne varijable, $R^2 = 0,9757$ i podešeni $R^2 = 0,9332$ i to su najviše vrijednosti oba pokazatelja koje je moguće postići modelom. Stoga, vrijednosti R^2 i podešenog R^2 koje su dane u tablicama 4.11., 4.12. i 4.13. su prihvatljive i u redu s obzirom na to da predloženi modeli imaju jednu, dvije ili maksimalno tri varijable što je manje od maksimalnog broja varijabli uključenih u model u kojem slučaju vrijednosti prethodna navedena dva pokazatelja poprimaju najviše vrijednosti.

Kada se pogleda odnos ukupnog broja priključaka na kanalizaciju i prosječne godišnje količine odvođenja otpadnih voda, uočava se koeficijent korelacije $r = 0,8834$ uz p vrijednost od 0,000139. Promatrajući koeficijent korelacije od 0,8834, prema tablici 4.7., definira se da između varijabli prosječna godišnja količina otpadne vode i ukupan broj priključaka na

kanalizaciju postoji snažna pozitivna korelacija. Budući da je korelacija pozitivna, ona označava sukladan rast vrijednosti obje skupine varijabli [300]. Također, vrijednost p iznosi 0,000139 što je prema tablici 4.8. visoko statistički značajno ($0,000139 < 0,001$). Iz međusobne korelacije navedenih dviju varijabli može se zaključiti da broj priključaka na kanalizaciju ima utjecaj na količinu odvođenja otpadne vode.

5. RAZVOJ MODELA I VALIDACIJA MODELA PROCJENE TROŠKOVA ODRŽAVANJA KANALIZACIJSKOG SUSTAVA

5.1. Razvoj modela procjene troškova održavanja kanalizacijskog sustava

Za prethodno predložene varijable modela izračunata je srednja apsolutna pogreška (engl. *Mean Absolute Error*, MAE) te *Akaikeov* informacijski kriterij (engl. *Akaike's Information Criterion*, AIC) [301]. Srednja apsolutna pogreška je relativno jednostavna za izračunati, svakako je mjerilo pokazatelja točnosti modela, a prema [302] ona se preporučuje kao mjerilo odstupanja. AIC je predložio Hirotugu Akaike [303]–[305], a cilj izbora modela pomoću AIC kriterija je procijeniti gubitak informacija tako da je model s najmanjim očekivanim gubitkom informacija ekvivalentan odabiru modela s najmanjom vrijednosti AIC [306]. Stoga, upotrebom AIC-a smanjuje se mogućnost preprilagođenosti modela (engl. *overfitting*), smanjuje se broj varijabli. On pomaže odrediti i usporediti najbolje modele i „kažnjava“ modele s više varijabli budući da je poznato da model koji ima više varijabli ima bolje slaganje s podacima, ali to dovodi do opasnosti od preprilagođenosti modela [299].

Radi daljnje jednostavnosti analize varijabli modela i bolje preglednosti za svaku od, u prethodnom poglavlju, navedenih varijabli 14 modela dan je naziv koji se sastoji od riječi „model“ i broja. Tako model gdje je zavisna varijabla (koja je u svim modelima ista) troškovi održavanja kanalizacijskog sustava, a nezavisna varijabla ukupna duljina kanalizacijske mreže nosi naziv „model 01“. U daljnjem tekstu navodit će se samo takvi kratki naziv modela, a tablice 5.1., 5.2. i 5.3. služit će kao pregled, odnosno tumač koje su nezavisne varijable odabrane i koliko ih je u modelu.

Tablica 5.1. Nazivi modela s jednom nezavisnom varijablom

Varijabla modela	Naziv modela
Ukupna duljina kanalizacijske mreže	Model 01
Ukupan broj priključaka na kanalizaciju	Model 02
Broj crpnih stanica	Model 03
Prosječna godišnja količina odvođenja otpadnih voda	Model 04

Tablica 5.2. Nazivi modela s dvije nezavisne varijable

Variable modela	Naziv modela
Ukupna duljina kanalizacijske mreže Ukupan broj priključaka na kanalizaciju	Model 05
Ukupna duljina kanalizacijskog sustava Broj crpnih stanica	Model 06
Ukupna duljina kanalizacijske mreže Prosječna godišnja količina odvođenja otpadnih voda	Model 07
Ukupan broj priključaka na kanalizaciju Broj crpnih stanica	Model 08
Ukupan broj priključaka na kanalizaciju Prosječna godišnja količina odvođenja otpadnih voda	Model 09
Broj crpnih stanica Prosječna godišnja količina odvođenja otpadnih voda	Model 10


Tablica 5.3. Nazivi modela s tri nezavisne varijable

Variable modela	Naziv modela
Ukupna duljina kanalizacijske mreže Ukupan broj priključaka na kanalizaciju Broj crpnih stanica	Model 11
Ukupan broj priključaka na kanalizaciju Broj crpnih stanica Prosječna godišnja količina odvođenja otpadnih voda	Model 12
Ukupna duljina kanalizacijske mreže Broj crpnih stanica Prosječna godišnja količina odvođenja otpadnih voda	Model 13
Ukupna duljina kanalizacijske mreže Ukupan broj priključaka na kanalizaciju Prosječna godišnja količina odvođenja otpadnih voda	Model 14

Odлучilo se za maksimalno tri varijable budući da između nekih od varijabli postoji značajna korelacija što može dovesti do određenih netočnosti kod izrade regresijskog modela. Nadalje, kako se teži što jednostavnijoj primjeni izrađenog modela procjene, to je model koji ima jednu nezavisnu varijablu najjednostavniji za primjenu.

Na slici 5.1. prikazan je koeficijent determinacije (R^2) i podešeni koeficijent determinacije (podešeni R^2) za svih 15 modela koji su predloženi u tablicama gore. Za oba pokazatelja vrijedi da njihova vrijednost treba biti što bliže broju jedan, što bi značilo da odlično opisuju

prikupljene podatke. Oba pokazatelja imaju zajednički trend rasta, odnosno pada. Vidi se da model 03 ima najmanja dva pokazatelja. Model 01, kao model s jednom nezavisnom varijablom – ukupnom duljinom kanalizacijskog sustava ima vrlo visoka oba pokazatelja, a od modela s dvije nezavisne varijable ističe se model 06 čije su nezavisne varijable ukupna duljina kanalizacijskog sustava i broj crpnih stanica.



Slika 5.1. Vrijednosti koeficijenta determinacije i podešenog koeficijenta determinacije za promatrane modele

U tablici 5.4. za svaki od gore predloženih modela procjene troškova održavanja kanalizacijskog sustava dane su vrijednosti MAE i AIC kako bi se mogao napraviti daljnji odabir modela procjene troškova održavanja koji će biti predloženi i validirani na testnom uzorku te, na kraju, i usvojeni.

U tablici 5.4. prikazane su vrijednosti MAE i AIC te je iz navedene tablice vidljivo kako model 01, od modela s jednom varijablom ima najmanji MAE i AIC (cilj je imati što manji MAE i AIC), a od modela s dvije varijable to je slučaj kod modela 06. Također, model s jednom varijablom koji će ući u daljnju analizu je model 01.

Tablica 5.4. Vrijednosti MAE i AIC za predložene modele

Naziv modela	MAE	AIC
Model 01	533.998,4	360,4463
Model 02	685.501,3	370,4959
Model 03	802.015,7	376,3749
Model 04	583.127,2	369,4475
Model 05	476.325,1	360,243
Model 06	427.782,2	359,091
Model 07	531.263,6	362,4315
Model 08	698.981,9	372,3672
Model 09	592.805,5	370,6873
Model 10	609.270,9	369,5119
Model 11	377.459,6	356,9338
Model 12	607.508,4	371,5094
Model 13	405.506,6	358,2236
Model 14	433.878,3	361,4698

Osim tih 14 modela, napraviti će se i model s interakcijama (model 15). Općenito, za dvije varijable X_1 i X_2 kaže se da su u interakciji ako vrijednost varijable X_1 utječe na vrijednost varijable X_2 pozitivno ili negativno. Interakcija je sinergija između dviju ili više varijabli i odražava činjenicu da njihov kombinirani učinak na odgovor (rezultat) ne ovisi samo o vrijednosti pojedinačnih varijabli, već i o njihovim kombinacijama vrijednosti [307]. Interakcija se odnosi na to da veličina (vrijednost) utjecaja jedne nezavisne varijable na odgovor ovisi o određenoj vrijednosti druge nezavisne varijable [265], odnosno, kraće rečeno, to znači da postoji ovisnost jedne prediktorske varijable na vrijednost druge prediktorske varijable [308]. Vidi se da još nigdje nije u obzir uzeta varijabla položaj koja ima dvije, odnosno tri moguće vrijednosti („kopno malo“ – kanalizacijski sustavi u kontinentalnoj Hrvatskoj duljine manje od 200 km, „kopno veliko“ – kanalizacijski sustavi u kontinentalnoj Hrvatskoj duljine veće od 200 km i „more“ – kanalizacijski sustavi u primorskoj Hrvatskoj bez obzira na duljinu). Naziv varijable kopno malo dobit će svi oni kanalizacijski sustavi čija je ukupna duljina manja od 200 km i koji se nalaze u kontinentalnoj Hrvatskoj, kopno veliko su oni kanalizacijski sustavi u kontinentalnoj Hrvatskoj čija je duljina veća od 200 km, dok je more za sve one kanalizacijske sustave koji se nalaze u primorskoj Hrvatskoj. Navedene vrijednosti (kopno malo, kopno veliko, more) dobivene su pomnijom analizom dijagrama raspršenosti za varijable troškovi održavanja i ukupna duljina kanalizacijske mreže. Navedena tri dijagrama raspršenosti prikazana su u Prilogu 4. Kod kanalizacijskih sustava u primorskoj Hrvatskoj vidi

se različit regresijski pravac u odnosu na regresijski pravac za kontinentalnu Hrvatsku. Za kontinentalnu Hrvatsku postoji razlika regresijskog pravca za ukupnu duljinu kanalizacijskih sustava koji su duljine 200 km, i onih koji imaju duljinu veću od 200 km.

Za model 15 podatci o koeficijentu determinacije R^2 , podešenom koeficijentu determinacije, MAE i AIC dani su u tablici 5.5.

Tablica 5.5. Podatci za model s interakcijom (model 15)


Naziv modela	R^2	Podešeni R^2	MAE	AIC
Model 15	0,9238	0,8603	302.873,3	358,44

Kako model 15 – model s interakcijama ima izvrsne pokazatelje R^2 , podešeni R^2 , MAE i AIC to će i on biti uzet u daljnju analizu. Navedeni model s interakcijama za nezavisnu varijablu ima ukupnu duljinu kanalizacijskog sustava s obzirom na duljinu i položaj.


Na slici 5.2. prikazane su vrijednosti srednje apsolutne pogreške (MAE) za promatranih 15 modela, a na slici 5.3. vrijednosti *Akaikeovog* informacijskog kriterija (AIC) za istih 15 modela kao na prethodnoj slici.

Slika 5.2. prikazuje kako je kod promatrana četiri modela s jednom nezavisnom varijablom – ukupna duljina kanalizacijskog sustava, vrijednost MAE najmanja kod modela 01 i modela 04. Za modele s dvije varijable, vrijednost MAE je najmanja kod modela 06 čije su dvije nezavisne varijable ukupna duljina kanalizacijskog sustava i broj crpnih stanica. Kod svih promatranih modela, model 15 ima najmanji MAE. Svi prethodno navedeni modeli uzet će se u daljnju analizu.

Na slici 5.3. također se vidi da je kod promatrana četiri modela s jednom nezavisnom varijablom – ukupna duljina kanalizacijskog sustava, vrijednost AIC najmanja kod modela 01 i modela 04. Za modele s dvije varijable, vrijednost AIC je najmanja kod modela 06 čije su dvije nezavisne varijable ukupna duljina kanalizacijskog sustava i broj crpnih stanica. Kod svih promatranih modela, model 11 ima najmanju vrijednost AIC. Svi prethodno navedeni modeli uzet će se u daljnju analizu.



Slika 5.2. Vrijednosti srednje apsolutne pogreške za promatrane modele



Slika 5.3. Vrijednosti Akaikeovog informacijskog kriterija za promatrane modele

Cilj matematičkog modela je predviđanje (procjena) troškova održavanja kanalizacijskog sustava, stoga su modeli s najmanjom srednjom apsolutnom pogreškom i najmanjim *Akaikeovim* informacijskim kriterijem uzeti u daljnju obradu i validaciju.

Modeli s jednom varijablom su:

- Model 01
- Model 04

Modeli s dvije varijable su:

- Model 05
- Model 06

Modeli s tri varijable su:

- Model 11
- Model 13

Iz daljnje obrade isključeni su modeli s tri varijable. Model 11 ima tri nezavisne varijable, i to: ukupnu duljinu kanalizacijskog sustava, ukupan broj priključaka na kanalizaciju i broj crpnih stanica. Varijable ukupna duljina kanalizacijskog sustava i ukupan broj priključaka na kanalizaciju u snažnoj su pozitivnoj korelaciji budući da je koeficijent korelacije jednak 0,922.

Model 13 čije su tri nezavisne varijable: ukupna duljina kanalizacijskog sustava, broj crpnih stanica i prosječna godišnja količina odvođenja otpadnih voda također ima velike vrijednosti koeficijenta korelacije za promatrane varijable. Na primjer, varijable ukupna duljina kanalizacijskog sustava i prosječna godišnja količina odvođenja otpadnih voda imaju koeficijent korelacije 0,867, a varijable ukupna duljina kanalizacijskog sustava i broj crpnih stanica imaju koeficijent korelacije 0,782. Takva dva modela s tri varijable isključena su iz daljnje obrade zato što su te tri varijable već međusobno korelirane te takav model ne bi bio dobar, došlo bi do moguće pojave preprilagođavanja modela podacima te bi model s tri varijable već postao složeniji za uporabu, a njegova se uporaba vjerojatno ne bi opravdala budući da bi bila kompliciranija od modela s jednom ili dvije varijable. Procijenjeni regresijski koeficijenti bit će tim manje pouzdani što je veća korelacija između dvije ili više nezavisnih varijabli, a geometrijska interpretacija višestruke regresije, odnosno može se reći vizualno predočavanje, postaje sve složenije kako broj nezavisnih varijabli raste [261]. Nadalje, kod izrade modela pomoću višestruke linearne regresije preporučljivo je imati po 10 slučajeva za svaku nezavisnu varijablu koja je uključena u model. Tako na primjer ako se razmatra model s četiri prediktorske, nezavisne varijable, bilo bi poželjno imati uzorak od 40 slučajeva [286].

Pored gore navedenih razloga zašto treba težiti tome da se izradi i upotrebljava model koji je jednostavniji, postoje još tri prednosti jednostavnijih modela – modela s manje prediktorskih varijabli, a to su:

1. Sprječavanje preprilagođavanja podacima – skup podataka s puno dimenzija koji ima puno osobina ponekad može dovesti do toga da model uzima u obzir i stvarne i slučajne pojave u podacima.
2. Interpretabilnost – model koji je previše složen ima previše karakteristika koje je teško interpretirati, pogotovo u slučaju kada se uspoređi s jednostavnim modelom.
3. Računalna učinkovitost – model koji je izrađen na podacima s manje dimenzija je računalno učinkovitiji, tj. treba manje vremena za izračunavanje [309]. Stoga su svi modeli s tri varijable isključeni iz daljnje analize.

Model koji će se također uzeti u obzir je model 15, zbog prethodno opisanih razloga. Provodeći dodatnu analizu dva modela s jednom varijablom, dva modela s dvije varijable i modela s interakcijom, a uzimajući u obzir modele s dvije varijable, uzet će se model 06 od dva modela s dvije varijable budući da je navedeni model točniji i bolje opisuje analizirane podatke od modela 05 jer model 06 ima manji AIC i manji MAE.

Na temelju prethodnog dolazi se do konačno odabrana četiri modela koji su prikazani u tablici 5.6.

Tablica 5.6. Varijable modela procjene troškova održavanja s pripadajućim podacima

Naziv modela	Varijable modela	R^2	Podešeni R^2	MAE	AIC
Model 01	Ukupna duljina kanalizacijske mreže	0,8247	0,8072	533.998,4	360,44
Model 04	Prosječna godišnja količina odvođenja otpadnih voda	0,6287	0,5915	583.127,2	369,44
Model 06	Ukupna duljina kanalizacijske mreže Broj crpnih stanica	0,8673	0,8379	427.782,2	359,09
Model 15	Ukupna duljina kanalizacijske mreže Položaj	0,9238	0,8603	302.873,3	358,44

Kada se promotre vrijednosti koeficijenta determinacije R^2 i podešenog koeficijenta determinacije u tablici 5.6., vidljivo je kako svi predloženi modeli imaju zadovoljavajuće

vrijednosti koeficijenata za daljnju analizu. Vrijednosti MAE i AIC su prikazane te su zadovoljavajuće s obzirom na model 11 koji ima tri nezavisne varijable i čija vrijednost AIC je najmanja od promatranih 15 modela, odnosno model 15 čija vrijednost MAE je najmanja od svih promatranih 15 modela. S obzirom na ta dva modela definiran je pojam zadovoljavajućih vrijednosti. Kako bi se napravio konačni odabir modela procjene troškova održavanja kanalizacijskog sustava, napraviti će se validacija svih modela na testnom uzorku. Nakon toga, provest će se analiza osjetljivosti za odabrane modele.

5.1.1. Model I procjene troškova održavanja

Prvi model procjene troškova održavanja je model naziva „Model 01“ koji ima jednu varijablu – ukupnu duljinu kanalizacijskog sustava. Regresijskom analizom u programskom jeziku R dobiveni su regresijski koeficijent i konstanta.

Izraz za prvi model procjene troškova održavanja kanalizacijskog sustava glasi:

$$PGNTO = -406158,2 + 6321,7 \cdot UDK_M \quad (5.1)$$

Gdje su:

- PGNTO, prosječni godišnji nominalni troškovi održavanja
- UDK_M , ukupna duljina kanalizacijske mreže.

5.1.2. Model II procjene troškova održavanja

Drugi model procjene troškova održavanja je model naziva „Model 04“ koji ima jednu varijablu – prosječnu godišnju količinu odvođenja otpadnih voda. Regresijskom analizom u programskom jeziku R dobiveni su regresijski koeficijent i konstanta.

Izraz za drugi model procjene troškova održavanja kanalizacijskog sustava glasi:

$$PGNTO = 130800 + 0,2853 \cdot KOV \quad (5.2)$$

Gdje su:

- PGNTO, prosječni godišnji nominalni troškovi održavanja
- KOV, prosječna godišnja količina odvođenja otpadnih voda.

5.1.3. Model III procjene troškova održavanja

Treći model procjene troškova održavanja je model naziva „Model 06“ koji ima dvije varijable: ukupnu duljinu kanalizacijskog sustava i broj crpnih stanica. Regresijskom analizom u programskom jeziku R dobiveni su regresijski koeficijenti i konstanta.

Izraz za treći model procjene troškova održavanja kanalizacijskog sustava glasi:

$$PGNTO = -250789 + 8129 \cdot UDK_M - 1515 \cdot BCS \quad (5.3)$$

Gdje su:

- PGNTO, prosječni godišnji nominalni troškovi održavanja
- UDK_M , ukupna duljina kanalizacijske mreže
- BCS, broj crpnih stanica.

5.1.4. Model IV procjene troškova održavanja

Četvrti model procjene troškova održavanja je model naziva „Model 15“ koji ima dvije varijable: ukupnu duljinu kanalizacijskog sustava i položaj kanalizacijskog sustava u smislu da se promatra gdje se kanalizacijski sustav nalazi. Dvije mogućnosti gdje se kanalizacijski sustav može nalaziti su kontinentalna ili primorska Hrvatska. Regresijskom analizom u programskom jeziku R dobiveni su regresijski koeficijenti i konstanta.

Budući da je taj četvrti model s interakcijama, on se sastoji od tri izraza jer jedan je model za kanalizacijske sustave koji se nalaze u kontinentalnoj Hrvatskoj i čija je ukupna duljina manja od 200 km, drugi je model za kanalizacijske sustave koji se nalaze u kontinentalnoj Hrvatskoj i čija je duljina veća od 200 km, a treći je model za kanalizacijske sustave u primorskoj Hrvatskoj – moru bez obzira na duljinu.

Polazni izraz iz kojeg se izvode sva tri modela glasi:

$$PGNTO = -409506 + 10266 \cdot UDK_M - 189588 \cdot P_{KV} + 152546 \cdot P_M + 412 \cdot UDK_M \cdot P_{KV} - 3684 \cdot UDK_M \cdot P_M \quad (5.4)$$

Gdje su:

- PGNTO, prosječni godišnji nominalni troškovi održavanja

- UDK_M , ukupna duljina kanalizacijske mreže
- P_{KV} , položaj na kopnu – kontinentalna Hrvatska, kanalizacijski sustav duljine veće od 200 km
- P_M , položaj na moru – primorska Hrvatska (bez obzira na duljinu).

U slučaju da se radi o kanalizacijskom sustavu koji se nalazi na kopnu – kontinentalnoj Hrvatskoj i čija je duljina manja od 200 km, izraz za model procjene troškova održavanja kanalizacijskog sustava glasi:

$$PGNTO = -409506 + 10266 \cdot UDK_M \quad (5.5)$$

Gdje su:

- $PGNTO$, prosječni godišnji nominalni troškovi održavanja
- UDK_M , ukupna duljina kanalizacijske mreže.

U slučaju da se radi o kanalizacijskom sustavu koji se nalazi na kopnu – kontinentalnoj Hrvatskoj i čija je duljina veća od 200 km, izraz za model procjene troškova održavanja kanalizacijskog sustava glasi:

$$PGNTO = -2306094 + 10678 \cdot UDK_M \quad (5.6)$$

Gdje su:

- $PGNTO$, prosječni godišnji nominalni troškovi održavanja
- UDK_M , ukupna duljina kanalizacijske mreže.

U slučaju da se radi o kanalizacijskom sustavu koji se nalazi na moru – u primorskoj Hrvatskoj i bez obzira na duljinu, izraz za model procjene troškova održavanja kanalizacijskog sustava glasi:

$$PGNTO = -256960 + 6582 \cdot UDK_M \quad (5.7)$$

Gdje su:

- PGNTO, prosječni godišnji nominalni troškovi održavanja
- UDK_M , ukupna duljina kanalizacijske mreže.

U Tablici 5.7. dan je tablični prikaz svih prethodno razvijenih modela i to naziv modela, izraz za model te potreban ulazni podatak, odnosno ulazne varijable.

Tablica 5.7. Sažeti tablični prikaz razvijenih modela

Naziv modela	Izraz za model	Ulazni podatak
Model I	$PGNTO = -406158,2 + 6321,7 \cdot UDK_M$	duljina kanal. sustava
Model II	$PGNTO = 130800 + 0,2853 \cdot KOV$	godišnja količina otpadnih voda
Model III	$PGNTO = -250789 + 8129 \cdot UDK_M - 1515 \cdot BCS$	duljina kanal. sustava broj crpnih stanica
Model IV	$PGNTO = -409506 + 10266 \cdot UDK_M$	duljina kanal. sustava < 200 km, kopno
	$PGNTO = -2306094 + 10678 \cdot UDK_M$	duljina kanal. sustava > 200 km, kopno
	$PGNTO = -256960 + 6582 \cdot UDK_M$	duljina kanal. sustava bez obzira na duljinu, more

5.2. Validacija modela procjene troškova održavanja kanalizacijskog sustava

U svrhu validacije modela i utvrđivanja primjenjivosti modela za procjenu troškova održavanja kanalizacijskog sustava, dobivena četiri modela primijenjena su za procjenu troškova održavanja na kanalizacijskom sustavu koji je namijenjen za validaciju. Radi se o kanalizacijskom sustavu na kopnu, duljine veće od 200 km. U tablici 5.8. dani su osnovni podaci o kanalizacijskom sustavu i to samo one varijable sustava potrebne u modelima, a ostale su varijable izostavljene budući da nisu potrebne za procjenu troškova održavanja. Kanalizacijski sustav koji je namijenjen za validaciju je prema svim karakteristikama prikladan za validaciju zbog toga što se nalazi u Republici Hrvatskoj, u kontinentalnom dijelu te su

nezavisne varijable u rasponu podataka koji su korišteni za izradu modela. Uporaba modela (ekstrapolacija) regresijske jednadžbe izvan raspona vrijednosti podataka koji su korišteni za procjenu se ne preporučuje [261], odnosno upotreba regresijske jednadžbe izvan područja korištenih podataka je riskantna [310]. Iz tih se razloga odlučilo da navedeni model bude model na kojem će se napraviti validacija izrađenih modela.

Prosječna godišnja količina odvođenja otpadnih voda dobivena je na način da je za sve godine za koje su dostavljeni podatci o godišnjoj količini otpadne vode zbrojene količine otpadne vode te su podijeljene s brojem godina, odnosno napravljen je prosjek. Također, za prosječne godišnje troškove održavanja napravljen je prosjek zbroja svih troškova održavanja za godine za koje je promatrani podatak dostavljen.

Tablica 5.8. Podatci o kanalizacijskom sustavu namijenjenom za validaciju

Naziv varijable	Vrijednost varijable
Ukupna duljina kanalizacijskog sustava [km]	289
Broj crpnih stanica [kom]	30
Prosječna godišnja količina odvođenja otpadnih voda [m ³]	4.799.604,70
Prosječna godišnja sadašnja vrijednost troškova održavanja [kn]	1.877.671,62
Prosječni godišnji nominalni troškovi održavanja [kn]	1.564.276,60

5.2.1. Metode validacije modela

Validacija modela važan je dio kod izrade regresijskog modela [285] te je to zadnji korak u njegovoj izgradnji. Validacijom se daje konačno odobrenje za model u smislu da on može biti korišten za predviđanje varijable od interesa, odnosno podatka koji se želi predvidjeti [286], [311]. Validacija je usporedba rezultata dobivenih predviđanjem pomoću modela sa stvarnim rezultatima kako bi se vidjelo je li model prikladan za namijenjenu svrhu [302], [312].

Validacija modela radi se iz sljedećih razloga: odabir najboljeg modela i kao mjera točnosti modela te iz statističkog razloga koji je utvrđivanje modela koji imaju najmanju pogrešku [313]. Svrha validacije dobivenog modela je sljedeća:

- Osigurati uporabljivost modela u budućnosti, odnosno da se model može koristiti na budućim, novim podacima koji su slični onima korištenima u izgradnji modela [314], [315].

- Izbjegavanje pojave prenaučenosti (*overfitting* – pojava kada je model odgovarajući samo za skup podataka koji su korišteni u izgradnji modela; prenaučeni model je model koji ima više parametara nego što može biti opravdano) i pojave podnaučenosti (*underfitting*) [315] (pojava kada izgrađenom modelu nedostaju određeni parametri, model dobro ne opisuje podatke ili kada nezavisne varijable nisu dovoljno značajne u definiranju veze između zavisne i nezavisnih varijabli) [316].

Kako je već prije navedeno, srednja apsolutna pogreška (MAE) je relativno jednostavna za izračun, a računa se kao zbroj apsolutnih vrijednosti pogreške, tj. razlike između stvarnih vrijednosti i vrijednosti dobivenih modelom podijeljenih s brojem opažanja (brojem slučajeva) [317]. Autori Willmott i Matsuura u svom su radu zaključili kako je MAE dobar indikator kvalitete modela te da najprirodnije pokazuje mjeru prosječne veličine pogreške [317] te je navedena mjera korisna i naširoko korištena u evaluaciji modela [318].

Srednja apsolutna pogreška računa se prema sljedećem izrazu (prema: [319], [320]):

$$MAE = \frac{1}{n} \sum_{i=1}^n |T_{ODS} - T_{ODI}| \quad (5.8)$$

Gdje su:

- MAE, srednja apsolutna pogreška
- N, broj opažanja (slučajeva)
- T_{ODS} , stvarni troškovi održavanja
- T_{ODI} , troškovi održavanja izračunati modelom.

Osim navedene mjere, koristit će se i izraz za izračun točnosti modela (engl. *Model Accuracy*, A_C) koji se računa kao postotak razlike između vrijednosti troškova dobivenih modelom i vrijednosti stvarnih troškova. Što je vrijednost A_C bliža nuli, to je model točniji. Izraz za točnost modela je sljedeći [28]:

$$A_C = \left[\frac{PC - AC}{AC} \right] \cdot 100 \% \quad (5.9)$$

Gdje su:

- A_C , točnost izračunatih troškova

- PC, troškovi previđeni modelom
- AC, stvarni troškovi.

5.2.2. Validacija modela I procjene troškova održavanja kanalizacijskog sustava

U tablici 5.9. prikazani su rezultati validacije modela I čija je nezavisna varijabla ukupna duljina kanalizacijskog sustava. Dobivena procijenjena vrijednost je prosječna vrijednost troškova za jednu godinu održavanja kanalizacijskog sustava.

Tablica 5.9. Rezultati validacije modela I na testnom uzorku

Stvarna vrijednost	Procijenjena vrijednost	Točnost modela, A_c
1.564.276,60	1.420.813,10	-9,17 %

Provedenom validacijom modela pokazana je zadovoljavajuća točnost modela koja iznosi 9,17 % što je za uporabu modela više nego prihvatljivo, budući da vrijedi da je vrijednost A_c bliža nuli, što je model točniji. Model je prikladan za uporabu.

Srednja točnost modela I za promatrani kanalizacijski sustav za sve godine za koje su dostavljeni podatci u upitniku iznosi -6,78 %. Navedena točnost govori da je model prikladan za uporabu.

5.2.3. Validacija modela II procjene troškova održavanja kanalizacijskog sustava

U tablici 5.10. prikazani su rezultati validacije modela II čija je nezavisna varijabla prosječna godišnja količina odvođenja otpadnih voda.

Tablica 5.10. Rezultati validacije modela II na testnom uzorku

Stvarna vrijednost	Procijenjena vrijednost	Točnost modela, A_c
1.564.276,60	1.500.127,22	-4,10 %

Provedenom validacijom modela pokazana je veoma dobra, čak se može reći i izvrsna točnost modela koja iznosi 4,10 %, budući da vrijedi da je vrijednost A_c bliža nuli, što je model točniji [28]. Ako bi vrijednost A_c bila jednaka nuli, to bi značilo da je vrijednost koja se dobije procjenom pomoću modela jednaka onoj stvarnoj vrijednosti podatka koji se procjenjuje. Može se zaključiti da je takav model prikladan za uporabu kao model za procjenu troškova održavanja kanalizacijskog sustava.

Srednja točnost modela II za promatrani kanalizacijski sustav za sve godine za koje su dostavljeni podatci u upitniku iznosi 2,45 %. Navedena točnost govori da je model prikladan za uporabu.

5.2.4. Validacija modela III procjene troškova održavanja kanalizacijskog sustava

U tablici 5.11. prikazani su rezultati validacije modela III čije su nezavisne varijable ukupna duljina kanalizacijskog sustava i broj crpnih stanica.

Tablica 5.11. Rezultati validacije modela III na testnom uzorku

Stvarna vrijednost	Procijenjena vrijednost	Točnost modela, Ac
1.564.276,60	2.053.042,00	+31,24 %

Provedenom validacijom modela pokazana je nedovoljna točnost modela, iako bi se i takav model mogao koristiti za procjenu troškova održavanja zato što prethodna dva modela daju određen rezultat, odnosno određeni prosječni godišnji iznos troškova održavanja kanalizacijskog sustava. Za provjeru se može još i napraviti procjena troškova održavanja prema ovome modelu te na kraju usporediti dobiveni rezultati. Budući da ovaj model koristi dvije nezavisne varijable kod izračuna troškova održavanja, to se može očekivati da bi u određenim slučajevima bio točniji (davao bi procjene troškova koje su bliže stvarnom iznosu troškova održavanja) od prethodna dva modela. Također, kako se ovim modelom dobije nešto veći iznos troškova održavanja, može se odlučiti za taj veći iznos budući da je u tom slučaju procjenitelj na strani sigurnosti.

Srednja točnost modela III za promatrani kanalizacijski sustav za sve godine za koje su dostavljeni podatci u upitniku iznosi 34,71 %.

5.2.5. Validacija modela IV procjene troškova održavanja kanalizacijskog sustava

U tablici 5.12. prikazani su rezultati validacije modela IV čija je nezavisna varijabla ukupna duljina kanalizacijskog sustava s obzirom na položaj – nalazi li se u kontinentalnoj ili primorskoj Hrvatskoj.

Tablica 5.12. Rezultati validacije modela IV na testnom uzorku

Stvarna vrijednost	Procijenjena vrijednost	Točnost modela, Ac
1.564.276,60	779.848	-50,15 %

Provedenom validacijom modela pokazana je nezadovoljavajuća točnost modela, budući da je procjena koju takav model daje loša – procjena odstupa od stvarne vrijednosti za 50,15 % te takav model nije prikladan za uporabu.

Srednja točnost modela IV za promatrani kanalizacijski sustav za sve godine za koje su dostavljeni podatci u upitniku iznosi -48,83 %. Navedena točnost govori da model nije prikladan za uporabu.

Zaključuje se da su oba modela (model I i model II) prikladna za uporabu s obzirom na dobivenu točnost kod validacije na testnom uzorku. Također, za uporabu je prikladan i model III i procijenjeni iznos troškova održavanja koji se dobije pomoću tog modela trebao bi biti na strani sigurnosti budući da je iznos koji se dobije precijenjen (premašen). Uporabom takvog modela procijenjeni iznos troškova održavanja je veći od stvarnog troška održavanja. Međutim, važno je znati i uzeti u obzir da se pomoću sva tri modela dobiju prosječni godišnji troškovi održavanja kanalizacijskog sustava te, s obzirom na to da su to prosječni troškovi, jasno je da troškovi mogu biti manji, ali i veći od te prosječne vrijednosti. Samim time moguće je da u određenoj godini troškovi koji su sada veći, budu u budućnosti bliže toj procijenjenoj vrijednosti. Stoga je i uporaba ovog modela opravdana.

Za sva tri promatrana modela (I, II i III) napraviti će se analiza osjetljivosti.

5.3. Analiza osjetljivosti modela procjene troškova održavanja kanalizacijskog sustava

Analiza osjetljivosti omogućava donositelju odluke da odgovori na niz pitanja tipa: „Što ako...?“ [321], [322]. Analiza osjetljivosti zapravo je slučaj analize što-ako koja uključuje ponovljene promjene samo jedne varijable odjednom. Neki paketi za potporu odlučivanju automatski ponavljaju male promjene na varijabli kada se zatraži izvršavanje analize osjetljivosti. Donositelji odluka u pravilu koriste analizu osjetljivosti kada nisu sigurni u pretpostavke donesene prilikom procjene vrijednosti određenih ključnih varijabli [321]. Kod analize osjetljivosti treba izabrati „kritične varijable“ [323] i parametre modela. Kritične varijable su one čije (pozitivne ili negativne) varijacije imaju najjači utjecaj na pokazatelje učinkovitosti promatranog projekta [243]. Analiza osjetljivosti omogućuje korisniku modela utvrđivanje utjecaja ulaza u model na izlaz iz modela, odnosno istraživanje koliko je važan ulazni podatak modela na izlazni podatak [324]. Kod analiza osjetljivosti ulaznoj varijabli

dodjeljuje se nekoliko vrijednosti, te se prema tim vrijednostima računa vrijednost ovisne varijable te analizira njezina osjetljivost [325]. Analiza osjetljivosti može se završiti s analizom scenarija gdje se kombinira pesimističke i optimističke scenarije. Kako bi ih se definiralo, za svaku varijablu se bira ekstremna vrijednost unutar raspona koji je realističan [323].

Neke od motivacija za analizu osjetljivosti su:

- detektira stršće vrijednosti
- detektira krive vrijednosti podataka
- definira strategije testiranja
- optimizira resurse
- smanjuje troškove
- izbjegava neočekivane probleme [326].

Analiza osjetljivosti sastavni je dio procesa modeliranja [327] te je njezin neizostavni dio [328]. Analiza osjetljivosti je metoda koja mjeri kako utjecaj nesigurnosti jedne ili više ulaznih varijabli može dovesti do nesigurnosti izlaznih varijabli. Ova je analiza korisna budući da poboljšava predviđanje modela ili smanjuje netočnost predviđanja proučavanjem kvalitativnog i/ili kvantitativnog odgovora modela na promjenu ulaznih varijabli. U analizi osjetljivosti, očekivane vrijednosti različitih uključenih parametara mogu se koristiti za ocjenu robusnosti, tj. „osjetljivosti” rezultata tih promjena i utvrđivanje vrijednosti iznad kojih se rezultati značajno mijenjaju [329].

Kod provođenja analize osjetljivosti varijable uobičajeno variraju od -10 (20) % do +10 (20) %, što olakšava i ubrzava proračun, ali uopće ne mora odgovarati mogućim rasponima promjene promatrane varijable [330]. Iznosi promjene varijable trebaju biti u granicama u kojima se očekuje moguća promjena varijabli [330]. Rezultati analize osjetljivosti najjasnije se mogu prikazati grafički na način da se u koordinatni sustav unose podatci o kretanju jedne od izlaznih varijabli u ovisnosti o ispitivanom smanjenju ili povećanju određene ulazne varijable [331] te je takav grafički prikaz najlakši za interpretaciju rezultata [332]. Grafički prikaz provedene analize osjetljivosti na odabranim modelima procjene troškova održavanja prikazan je na slikama 5.4., 5.5., 5.6. i 5.7.


Analiza osjetljivosti ima tri glavna ograničavajuća faktora:

- Ne uzima u obzir vjerojatnost pojavljivanja analiziranog događaja.

- Ne uzima u obzir korelacije između ulaznih parametara.
- Uobičajena praksa variranja ulaznih varijabli je od ± 10 do 20 % koja se najčešće koristi u praksi, a uopće ne mora odgovarati stvarnim rasponima ulaznih parametara (varijabli) [330].

5.3.1. Analiza osjetljivosti modela I procjene troškova

Za model I napravljena je analiza osjetljivosti. Kako je ulazna varijabla ukupna duljina kanalizacijskog sustava, to je ista varirana od -20 % do $+20$ % u koracima od po 5 %. Navedeno je moguće u stvarnosti budući da ima kanalizacijskih sustava različitih duljina tako da je ova analiza osjetljivosti opravdana. Analiza osjetljivosti provedena je na testnom kanalizacijskom sustavu.




Slika 5.4. Rezultati analize osjetljivosti modela I

Utjecaj koji promjena duljine kanalizacijskog sustava ima na promjenu troškova održavanja vidi se na slici 5.4. Promjena duljine kanalizacijskog sustava od ± 5 % utječe na promjenu troškova održavanja kanalizacijskog sustava od oko ± 6 %. Također, kod promjene duljine kanalizacijskog sustava od 20 %, ona uzrokuje povećanje troškova održavanja od 20,46 %. Smanjenje duljine kanalizacijskog sustava za 20 % uzrokuje smanjenje troškova održavanja od 34,62 %. Sve prethodno navedeno govori da, prema ovim rezultatima, promjena duljine kanalizacijskog sustava na više u određenoj mjeri uzrokuje proporcionalno povećanje troškova

održavanja kanalizacijskog sustava. U slučaju smanjenja duljine kanalizacijskog sustava, vidi se da je smanjenje troškova veće od postotka smanjenja duljine. Promjena duljine kanalizacijskog sustava značajno utječe na troškove održavanja kanalizacijskog sustava te je potrebno pažljivo razmotriti iznos duljine kanalizacijskog sustava koji se koristi u modelu.

5.3.2. Analiza osjetljivosti modela II procjene troškova

Na modelu II napravljena je analiza osjetljivosti. Kako je ulazna varijabla prosječna godišnja količina odvođenja otpadnih voda, ona je varirana od -20% do $+20\%$ u koracima od po 5% . Budući da je već prije navedeno da je potrebno voditi računa da ulazna varijabla koja se mijenja može poprimiti vrijednosti variranja, to je kod varijable „prosječna godišnja količina odvođenja otpadnih voda“ moguće, jer količina odvođenja otpadnih voda može poprimiti takve nove vrijednosti. Analiza osjetljivosti provedena je na modelu II, a za testni kanalizacijski sustav. Na slici 5.5. prikazani su rezultati analize osjetljivosti modela II procjene troškova održavanja kanalizacijskog sustava.



Slika 5.5. Rezultati analize osjetljivosti modela II

Kako se vidi na slici 5.5., prisutna je određena osjetljivost modela na promjenu vrijednosti ulazne varijable. Kod porasta vrijednosti ulazne varijable vidljivo je proporcionalno povećanje, odnosno u slučaju smanjenja vrijednosti ulazne varijable također se uočava proporcionalno smanjenje troškova održavanja kanalizacijskog sustava. Navedeno govori da je kod uporabe


modela potrebno pažljivo unositi količinu otpadne vode. Također, količina otpadne vode svakako se mijenja svake godine, tako da je potrebno za svaku godinu ažurirati količinu otpadne vode.

Sve nezavisne varijable mogu poprimiti različite vrijednosti, stoga je variranje svake varijable provedeno za realne mogućnosti. Naravno, nezavisne varijable mogu biti i manje i veće što je pokazano u slučaju ovog istraživanja gdje podatci o duljini kanalizacijskog sustava variraju od cca 5 do cca 750 km.

5.3.3. Analiza osjetljivosti modela III procjene troškova


Na modelu III napravljena je analiza osjetljivosti. Kako su dvije ulazne varijable: ukupna duljina kanalizacijskog sustava i broj crpnih stanica, to su obje ulazne varijable, i to svaka zasebno, varirane od -20% do $+20\%$ u koracima od po 5% .

Ukupna duljina kanalizacijskog sustava može poprimiti vrijednosti broja decimalnog zareza, dok kod broja crpnih stanica to nije moguće. Stoga, kod analize osjetljivosti broja crpnih stanica, dobiveni broj crpnih stanica varirat će se u koracima od po 10% i to od -40% do $+40\%$ budući da broj crpnih stanica može biti samo cijeli broj, a korak variranja od po 10% osigurava navedeno. Također, ako bi se radilo variranje od po 5% , iznos promjene bi iznosio 1,5 crpnu stanicu što je premalo u analizi osjetljivosti. Analiza osjetljivosti modela III prikazana je na slikama 5.6. i 5.7.



Slika 5.6. Rezultati analize osjetljivosti modela III za varijablu ukupna duljina kanal. sustava

Kod modela III za promjenu ulazne varijable – duljina kanalizacijskog sustava uočava se kako porast duljine kanalizacijskog sustava proporcionalno prati i povećanje troškova održavanja. Kod smanjenja duljine kanalizacijskog sustava uočava se da je smanjenje troškova održavanja neproporcionalno smanjenju duljine kanalizacijskog sustava. Zaključuje se da je duljina kanalizacijskog sustava važna varijabla za procjenu troškova održavanja u modelu III.



Slika 5.7. Rezultati analize osjetljivosti modela III za varijablu broj crpnih stanica

Kod modela III za promjenu ulazne varijable – broj crpnih stanica uočava se kako je kod porasta, odnosno smanjenja broja crpnih stanica prisutno vrlo malo povećanje, odnosno smanjenje troškova održavanja kanalizacijskog sustava. Stoga, ulazna varijabla, broj crpnih stanica, nije u toj mjeri važna ulazna varijabla, kao što je varijabla duljina kanalizacijskog sustava.

5.4. Prednosti i ograničenja modela procjene troškova održavanja kanalizacijskog sustava

5.4.1. Prednosti modela procjene troškova održavanja

Prednost primjene modela procjene troškova održavanja kanalizacijskog sustava je jednostavnost uporabe modela što je već i prije spomenuto kao jedna karakteristika dobrog modela. Varijabla koja je potrebna za procjenu troškova je ukupna duljina kanalizacijske mreže

ili prosječna godišnja količina odvođenja otpadnih voda, budući da se moguće odlučiti za oba modela ovisno s kojim se podacima raspolaže, ili da se napravi međusobna usporedba procjene troškova održavanja koja se dobije pomoću oba modela te odabere ona vrijednost koja je kritičnija. Također, kao treća varijabla je položaj gdje se kanalizacijski sustav nalazi te njegova duljina (je li duljine do 200 km ili je preko 200 km – vrijedi samo za one kanalizacijske sustave koji su na kopnu, dok u primorskoj Hrvatskoj nije važna duljina za varijablu položaj). Četvrta varijabla koja se može uzeti u obzir je broj crpnih stanica, a koji podatak je također dostupan kod projektiranja kanalizacijskog sustava. Navedene su varijable dostupne već na početku planiranja i izrade projekta izgradnje kanalizacijskog sustava. S obzirom na sve navedeno, navedenim modelom moguće je procijeniti troškove održavanja kanalizacijskog sustava.

Model je rađen na podacima kanalizacijskih sustava u Republici Hrvatskoj te je slijedom toga primjenjiv za cijelo područje RH.

Rezultat uporabe modela procjene troškova održavanja kanalizacijskog sustava je vrijednost prosječnih godišnjih troškova održavanja kanalizacijskog sustava koji su jednaki za svaku godinu održavanja u promatranom referentnom periodu.

Uporabom modela procjene troškova održavanja otvaraju se nove mogućnosti u planiranju potrebnog budžeta za održavanje kanalizacijskog sustava te na taj način održavanje postaje učinkovitije. Poduzeća koja upravljaju kanalizacijskom sustavom nekog grada, naselja ili općine mogu planirati u svom proračunu potrebni iznos koji će prosječno na godišnjoj razini trebati utrošiti za održavanje kanalizacijskog sustava. Slijedom toga, kako bi poduzeća koja su zadužena za upravljanje kanalizacijskim sustavom mogla procijeniti novčana sredstva za održavanje kanalizacije na razini područja na kojem djeluju, to bi i jedinice područne (regionalne) samouprave – u naravi županije – mogle procjenjivati potreban budžet za održavanje kanalizacijskih sustava na svom području. Ako bi se navedeno provelo za svaku županiju, mogao bi se procijeniti budžet za održavanje kanalizacijskih sustava za cijelu Republiku Hrvatsku.

5.4.2. Ograničenja modela procjene troškova održavanja

Prvo i najvažnije ograničenje modela je manji broj podataka na kojima je model rađen te na kojima je validiran. Uobičajeno se podatci o troškovima smatraju poslovnom tajnom te se očekivalo da će to dosta otežati prikupljanje podataka. Također, evidencije o troškovima koje vode poduzeća zadužena za upravljanje kanalizacijskim sustavima su, u većini slučajeva,

nepotpune, nisu točno vođene ili je teško do njih doći. Neka su poduzeća dostavila djelomično ispunjene upitnike (ispunili su ih najbolje što su mogli, s podacima kojima su raspolagali), ali ti djelomično ispunjeni upitnici nisu bili valjani za daljnju analizu. Svakako je potrebno i preporučljivo, u svrhu daljnjeg korištenja modela, povećati broj uzoraka za validaciju, kao i za samu izradu modela. Kako je veliko ograničenje kod prikupljanja podataka o troškovima održavanja kanalizacijskih sustava bila nerazvijena struktura troškova, u ovom istraživanju ona je razvijena, a sve u svrhu kako bi se troškovi mogli bolje evidentirati i voditi na godišnjoj razini za svaki pojedinačni kanalizacijski sustav.

Drugo ograničenje vezano je za broj godina na koji se procjenjuju troškovi održavanja kanalizacijskog sustava. Razdoblje za koje su dostavljeni podatci o troškovima održavanja kanalizacijskog sustava kreće se od 2 do 10 godina te, s obzirom na to, moguće je procijeniti troškove za maksimalno razdoblje od 10 godina. Izračunata regresijska jednadžba valjana je za određeno područje koje je omeđeno minimalnim i maksimalnim vrijednostima zavisne i nezavisne varijable (ili zavisnih varijabli) te je upotreba jednadžbe modela izvan tog područja riskantna [310]. Međutim, deset godina nije kratko razdoblje, a u tih prvih deset godina za koje je korišten model za procjenu moguće je prikupiti nove podatke o troškovima održavanja te s takvim, novoprikupljenim podacima izmijeniti postojeći, predloženi model, odnosno vidjeti u kojoj se mjeri modelirani podatci poklapaju sa stvarnim, praćenim podacima te ponovno validirati model.

Treće ograničenje vezano je za vrijednosti nezavisnih varijabli pomoću kojih se procjenjuje zavisna varijabla – troškovi održavanja kanalizacijskog sustava. Potrebno je da sve nezavisne varijable budu u rasponu podataka koji je korišten u izradi modela, budući da inače uporaba takvog modela nije preporučljiva. Nezavisna varijabla koja se koristila za izradu modela procjene troškova održavanja kanalizacijskog sustava je prosječna godišnja količina odvođenja otpadnih voda koja je bila u iznosu od 4.197,33 m³ do 14.223.945 m³ što govori da je za takve raspone podataka moguće koristiti model. Također, druga nezavisna varijabla koja je duljina kanalizacijskog sustava poprimila je vrijednosti od 5,1 km do 752,42 km što govori da se u tom rasponu model može koristiti. Treća nezavisna varijabla kretala se između jedne crpne stanice do maksimalne 92 crpne stanice što također govori kako se model može primijeniti za raspone unutar prethodno navedenih vrijednosti. Ukupno gledajući, sva tri raspona nezavisnih varijabli su velika, stoga je za smatrati kako se sva tri modela, ovisno koje nezavisne varijable uzimaju u obzir, mogu koristiti u gore danim rasponima podataka.

Četvrto ograničenje je to što su kod izrade modela korišteni prosječni godišnji troškovi održavanja kanalizacijskog sustava, a u stvarnosti je sigurno da ti troškovi nisu i rijetko kada će biti jednaki svake godine, godinu za godinom. Prosječni godišnji sadašnji troškovi održavanja kanalizacijskog sustava su dobiveni tako da je primijenjena diskontna stopa od 3 % za svaku pojedinu godinu, zatim je izračunata ukupna sadašnja vrijednost troškova održavanja za godine za koje su dostavljeni podatci o održavanju te je na kraju napravljen prosjek sadašnje vrijednosti troškova održavanja koji su nazvani prosječna godišnja sadašnja vrijednost troškova održavanja.

5.5. Sažeti prikaz rezultata istraživanja

Ovaj dio rada prikazuje sažeti prikaz rezultata istraživanja provedenih u svrhu izrade ove doktorske disertacije. Analiza podataka koji su prikupljeni pomoću upitnika napravljena je pomoću programa *Statistica* te programskog jezika R. Sve navedeno korišteno je u kombinaciji kako bi se međusobno provjerili dobiveni rezultati provedenih istraživanja.

Za kvantifikaciju korelacija između zavisnih i nezavisnih varijabli izračunate su vrijednosti *Pearsonovog* koeficijenta korelacije između zavisnih varijabli: prosječne godišnje sadašnje vrijednosti troškova održavanja i prosječnih godišnjih nominalnih troškova održavanja te svih nezavisnih varijabli. Analizom je utvrđeno da postoji nekoliko izraženijih korelacija između neovisnih varijabli i troškova održavanja. Najveću korelaciju troškovi održavanja imaju sa sljedećim nezavisnim varijablama: ukupna duljina kanalizacijskog sustava, ukupan broj priključaka na kanalizaciju, broj crpnih stanica te prosječnom godišnjom količinom odvođenja otpadnih voda. Uočeno je da je najveća korelacija s ukupnom duljinom kanalizacijskog sustava što je i za očekivati budući da je to u nekoj mjeri jedna od najvažnijih karakteristika kanalizacijskog sustava, uz prosječnu godišnju količinu odvođenja otpadnih voda, kao što je kod stambenih zgrada površina prostorija jedna od najvažnijih karakteristika same zgrade. Ukupna duljina kanalizacijskog sustava i prosječna godišnja količina odvođenja otpadnih voda pokazuju značajnu korelaciju s troškovima održavanja.

Odabirom značajnijih varijabli napravljeni su modeli za procjenu troškova održavanja kanalizacijskog sustava. Pomoću linearne regresije napravljeni su modeli te su validirani na testnom uzorku. Model koji za nezavisnu varijablu ima ukupnu duljinu kanalizacijskog sustava daje točnost od -9,17 %, model koji ima za nezavisnu varijablu prosječnu godišnju količinu odvođenja otpadnih voda ima točnost od -4,10 %, dok model koji za nezavisnu varijablu ima

ukupnu duljinu kanalizacijskog sustava i broj crpnih stanica ima točnost od +31,24 %. Prva dva modela (model I i model II) su primjenjiva za procjenu troškova održavanja kanalizacijskog sustava, dok je treći model (model III) također primjenjiv budući da on koristi dvije nezavisne varijable te bi u određenim slučajevima gdje se raspolože s ukupnom duljinom kanalizacijskog sustava i brojem crpnih stanica mogao dati bolju procjenu. Treći model daje veće procjene te bi tada osoba koja koristi takav model trebala biti na strani sigurnosti. Svakako bi preporuka kod uporabe modela procjene bila ta da se napravi procjena prema sva tri modela te se odluči za onu vrijednost procjene troškova održavanja koja je veća ili da se donosi odluka na temelju prethodnih vrijednosti troškova održavanja promatranog kanalizacijskog sustava u slučaju da je kanalizacijski sustav već prije u uporabi. Naravno, model procjene troškova održavanja kanalizacijskog sustava ima najveću vrijednost za one kanalizacijske sustave koji se tek projektiraju, grade i za koje se u tom slučaju mogu procijeniti troškovi održavanja u budućnosti i na taj način planirati određeni budžet za održavanje.

6. ZAKLJUČCI I SMJERNICE ZA DALJNJA ISTRAŽIVANJA

6.1. Zaključak

U svrhu izrade ove doktorske disertacije napravljeno je istraživanje o karakteristikama i troškovima održavanja kanalizacijskih sustava na području Republike Hrvatske. Takvo istraživanje o troškovima održavanja kanalizacijskih sustava još nije provedeno u Republici Hrvatskoj, te do sada još nisu postojali podaci o troškovima održavanja kanalizacijskih sustava. Upitnici su poslani poduzećima koja upravljaju sustavima javne odvodnje. Podatci koji su traženi u upitniku su opći podaci o poduzeću, održavanju, podaci o kanalizacijskom sustavu, količinama odvođenja otpadnih voda, o kanalizacijskim cijevima te podaci o troškovima održavanja kanalizacijskog sustava. Tijekom provođenja istraživanja u svrhu izrade ove doktorske disertacije utvrdilo se da poduzeća zadužena za upravljanje kanalizacijskim sustavima ne vode redovitu i ažurnu evidenciju o samim troškovima održavanja, kvarovima i svemu ostalome vezanim uz problematiku održavanja kanalizacijskih sustava te da imaju određenu zadržku prema davanju podataka o troškovima. Unutar same doktorske disertacije prikazani su dobiveni rezultati provedenog istraživanja te važne i nove spoznaje iz predmeta istraživanja.

Pregledom i analizom literature razvijena je odgovarajuća struktura troškova održavanja kanalizacijskog sustava koja je napravljena kako bi se poduzećima zaduženima za upravljanje i održavanje kanalizacijskih sustava olakšala sistematizacija troškova, odnosno prikupljanje podataka za svaku pojedinu godinu. Kod istraživanja u svrhu izrade doktorske disertacije razvijena je i predložena struktura troškova održavanja kanalizacijskog sustava. Razvijena struktura troškova održavanja kanalizacijskog sustava može pomoći kod prikupljanja podataka te razvoju točnijih modela procjene troškova održavanja kanalizacijskih sustava.

Baza podataka na temelju koje su stvoreni modeli za procjenu troškova održavanja kanalizacijskih sustava sastavljena je od raznih vrsta podataka o kanalizacijskim sustavima za cijelo područje Republike Hrvatske (kontinentalna i primorska Hrvatska) i to za razdoblje od 2009. do 2018. godine. Kada su prikupljeni podaci, pristupilo se analizi podataka i proučavanju karakteristika kanalizacijskih sustava koje najviše utječu na troškove održavanja istih. Također, detaljnim i iscrpnim pregledom literature iz područja održavanja građevina i područja kanalizacijskih sustava došlo se do određenih pretpostavki o karakteristikama kanalizacijskih sustava koje u najvećoj mjeri utječu na troškove njihovog održavanja.

Istraživanjem je utvrđeno da je moguće prikupljanje povijesnih podataka o troškovima održavanja kanalizacijskih sustava kao i o osnovnim karakteristikama istih. Također je istražena mogućnost stvaranja modela za procjenu troškova održavanja kanalizacijskih sustava u Republici Hrvatskoj. Utvrđeno je da je moguća primjena linearne regresije pri izradi navedenog modela. Međutim, moguća je i primjena višestruke linearne regresije, ali radi jednostavnosti same upotrebe, što je također jedno od nastojanja pri izradi modela procjene troškova održavanja, odlučilo se za jednostavnu linearnu regresiju. Budući da jednostavna linearna regresija za procjenu vrijednosti zavisne varijable, u ovom slučaju troškova održavanja, koristi jednu nezavisnu varijablu, to je uporaba jednostavne linearne regresije kod izrade modela jednostavna i praktična, a takav je model jednostavan za uporabu i razumljiv korisnicima istoga. Potrebno je uvijek optimizirati između složenosti modela, vremena potrebnog za izračun, kao i dostatne točnosti modela, a u ovom je slučaju jednostavna linearna regresija zadovoljila sva tri kriterija. Navedeno omogućuje najjednostavniju moguću primjenu modela procjene troškova održavanja kanalizacijskog sustava što je jedan od važnih preduvjeta da se model uopće koristi.

Utvrđeno je da su karakteristike koje najviše utječu na troškove održavanja kanalizacijskog sustava sljedeće: ukupna duljina kanalizacijske mreže, prosječna godišnja količina odvođenja otpadnih voda, broj crpnih stanica te lokacija (nalazi li se kanalizacijski sustav u primorskoj ili kontinentalnoj Hrvatskoj). Nakon što su izrađeni preliminarni modeli, kojih je bilo 15, prema podešenom R^2 , MAE i AIC kriteriju odlučilo se na temelju vrijednosti navedenih kriterija o modelima koji ulaze u daljnje razmatranje. Na temelju prethodnih kriterija odabrana su četiri modela. Nakon njihove validacije, usvojen je model gdje je nezavisna varijabla prosječna godišnja količina odvođenja otpadnih voda. Međutim, i model koji kao nezavisnu varijablu ima ukupnu duljinu kanalizacijskog sustava mogao bi biti korišten budući da pokazuje zadovoljavajuću točnost od -9,17 % na testnom uzorku. Ovaj uzorak ostavljen je upravo za validaciju modela. Model je točniji što je vrijednost točnosti bliže nuli, a kod modela I je to već prije spomenutih -9,17 %. Model koji ima za nezavisnu varijablu ukupnu duljinu kanalizacijskog sustava ima koeficijent determinacije R^2 od 0,8247, a model koji za nezavisnu varijablu ima prosječnu godišnju količinu odvođenja otpadnih voda ima koeficijent determinacije R^2 od 0,6287. Budući da su modeli izrađeni na podacima o karakteristikama i troškovima održavanja kanalizacijskih sustava, odnosno nezavisnim varijablama unutar određenih granica, to je potrebno voditi računa da se model koristi unutar tih raspona kako bi se dobile procjene troškova održavanja kanalizacijskog sustava određene točnosti.

Na temelju prethodnog, može se zaključiti da su ostvareni ciljevi u sklopu istraživanja za izradu doktorske disertacije od koji su neki bili istražiti mogućnost prikupljanja povijesnih podataka o karakteristikama i troškovima održavanja kanalizacijskih sustava, istražiti mogućnosti stvaranja modela procjene troškova održavanja kanalizacijskog sustava, definirati prednosti i ograničenja takvog modela.

Postavljene hipoteze su dokazane. Moguće je stvoriti bazu podataka o troškovima održavanja kanalizacijskih sustava u Republici Hrvatskoj, definirana je metodologija za uključivanje određenih karakteristika kanalizacijskih sustava u svrhu procjene troškova održavanja istih i utvrđen je utjecaj određenih karakteristika na troškove održavanja te je razvijen model za procjenu tih troškova.

Predloženim modelima procjene moguće je s određenom točnošću procijeniti prosječne godišnje troškove održavanja kanalizacijskog sustava. Naravno, uvijek je potrebno sve modele, pa tako i ove, koristiti pažljivo i pametno jer modeli samo predstavljaju stvarnost više ili manje dobro. U svakom slučaju, modeli koji su razvijeni u ovoj doktorskoj disertaciji bit će od koristi poduzećima koja upravljaju kanalizacijskim sustavima budući da će im omogućiti određivanje i procjenu budžeta koji je potreban za održavanje na godišnjoj razini. Kada poduzeća budu mogla procijeniti određeni budžet koji im je potreban za održavanje kanalizacijskog sustava kojim upravljaju, mogućnost za bolje održavanje bit će veća budući da će biti osigurana sredstva za održavanje. Sama će poduzeća u manjoj mjeri premašivati neke unaprijed određene budžete za održavanje, koji su se do sada određivali na manjoj razini točnosti i to vjerojatno bez nekog izračuna koji bi dao veću točnost ili pouzdanost o informaciji o visini troškova održavanja.

Budući da je definiran model procjene troškova održavanja, to je i definirano koje karakteristike kanalizacijskih sustava najviše utječu na troškove održavanja kanalizacijskog sustava. Pomoću takvih karakteristika omogućuje se već u fazi projektiranja procjena troškova održavanja što će omogućiti bolje održavanje budući da će određena novčana sredstva biti moguće osigurati u proračunu i unaprijed odrediti.

Kod izrađenog modela definirane su prednosti i ograničenja. Najvažnija i osnovna prednost modela je jednostavnost primjene budući da su navedeni podatci lagano dostupni već u fazi projektiranja kanalizacijskog sustava. Kada bi se model implementirao i koristio na velikom broju poduzeća koja upravljaju kanalizacijskim sustavima te kada bi se svake godine prikupljali podatci o troškovima održavanja kanalizacijskih sustava i sve unosilo u bazu podataka na razini

cijele Republike Hrvatske, to bi uvelike omogućilo veću točnost i primjenjivost modela. Također, za bolju točnost modela bilo bi potrebno prikupiti podatke za veći broj godina te svake godine iznova kontrolirati točnost uz eventualno potrebno kalibriranje. Nadalje, u Republici Hrvatskoj se dosta provode projekti izgradnje kanalizacijskih sustava te bi bilo zanimljivo i potrebno pratiti određene novoizgrađene kanalizacijske sustave od samog puštanja u uporabu (dobivanja uporabne dozvole) pa nadalje, u smislu praćenja stanja kanalizacijskih sustava te troškova održavanja istih. Tek tada bi model procjene troškova održavanja kanalizacijskog sustava bio još točniji i primjenjiviji.

Osnovno ograničenje modela je što je izrađen za područje Republike Hrvatske, a također je potrebno prikupiti i veći broj podataka te provesti prethodno navedene aktivnosti u cilju povećanja točnosti modela. Tek nakon toga bi se trebala utvrditi primjenjivost modela na kanalizacijske sustave izvan Republike Hrvatske.

6.2. Smjernice za daljnja istraživanja

Budući da istraživanje ovakve vrste o troškovima održavanja kanalizacijskih sustava nije još provedeno u Republici Hrvatskoj, ono je podloga za daljnja istraživanja. Kako bi se dobili što pouzdaniji rezultati, potrebno je istražiti veći broj slučajeva (veći uzorak), odnosno istraživanje proširiti na više poduzeća na području Republike Hrvatske. Treba podići razinu osviještenosti projekatanta i osoba koji upravljaju održavanjem kanalizacijskih sustava o cjeloživotnim troškovima kanalizacijskih sustava, a u sastavu kojih se nalaze troškovi održavanja. Također, postoji mogućnost proširenja istraživanja na nekoliko država unutar Europske unije gdje bi se vidjela primjenjivost modela izvan RH. Isto tako bi se moglo ispitati vremensko ograničenje (razdoblje) za koje je primjenjiv model procjene troškova održavanja. Ispitivanje vremenskog ograničenja moguće je na način da se troškovi prate na godišnjoj razini, više godina uzastopno za različite kanalizacijske sustave.

Kako bi se omogućilo lakše prikupljanje i analiza podataka o troškovima održavanja kanalizacijskih sustava, potrebno je razviti sustav zajedničkog prikupljanja podataka na razini cijele Republike Hrvatske što bi onda omogućilo jednakovrijednu usporedbu za kanalizacijske sustave na cijelom području RH. Kod izrade upitnika koji su poslani poduzećima zaduženima za održavanje kanalizacijskih sustava u Republici Hrvatskoj, istraživanjem i pregledom literature, razvijena je struktura troškova održavanja kanalizacijskih sustava. Navedena struktura troškova i pripadajućih podataka o funkcioniranju kanalizacijskih sustava omogućuje

Iako praćenje troškova na godišnjoj razini, a takvim pristupom osigurava se međusobna usporedivost troškova o održavanju kanalizacijskih sustava u Republici Hrvatskoj kao i mogućnost izrade i ažuriranja modela procjene troškova održavanja koji će dati točnije rezultate. Ako bi se koristila razvijena struktura troškova, baze podataka bile bi homogenije, te bi se na taj način omogućilo lakše praćenje troškova i izrada točnijih modela procjene troškova održavanja.

Izrada modela procjene troškova mogla bi se napraviti uporabom umjetnih neuronskih mreža koje bi mogle dati manje pogreške u procjeni vrijednosti troškova održavanja u odnosu na model napravljen regresijom. Međutim, za izradu modela pomoću umjetnih neuronskih mreža potreban je nešto veći broj podataka. S obzirom na postojeće stanje realno je očekivati prvo razvoj regresijskih modela na homogenim bazama podataka, a u idućem koraku razvoj modela baziranih na umjetnim neuronskim mrežama te istražiti njihov potencijal za točnije procjene troškova.

Postoji zadrška poduzeća koja upravljaju kanalizacijskim sustavima za davanje podataka o troškovima upravljanja i održavanja kanalizacijskih sustava te je uporaba umjetnih neuronskih mreža otežana ili u potpunosti onemogućena, a isto tako podatci moraju biti usporedivi u smislu da je struktura troškova ista ili barem podjednaka za sve kanalizacijske sustave. Isto tako, regresijski modeli su lakše razumljivi mogućim korisnicima modela i nisu potrebna računala za izračun, dok je kod umjetnih neuronskih mreža nemoguće izračunati troškove održavanja bez računala.

Sve što je povezano s novcem smatra se ili se može smatrati poslovnom tajnom, bilo kod privatnih bilo kod javnih institucija. Stoga je potrebno smanjiti, odnosno ukloniti otpor institucija na davanje takvih podataka, naravno za znanstveno-istraživačke svrhe. Kada bi ti podatci o troškovima o održavanju bili dostupniji, to bi imalo i velike koristi za sve dionike budući da bi omogućilo usporedbu, kao i izradu određenih modela pomoću kojih bi se mogli procijeniti ili predviđati troškovi što bi sve dovelo do učinkovitijeg održavanja. Osim toga, može se provesti i ispitivanje vremenskog ograničenja primjenjivosti izrađenog modela procjene troškova održavanja.

U daljnjim istraživanjima moguće je, ako se prikupi veći broj podataka o svim potrebnim karakteristikama kanalizacijskih sustava i troškovima održavanja istih, istražiti mogućnost stvaranja modela samo za kanalizacijske sustave koji se nalaze u primorskoj Hrvatskoj ili kontinentalnoj Hrvatskoj. Također, uz isti preduvjet (velik broj podataka), može se istražiti

mogućnost izrade modela procjene troškova održavanja kanalizacijskih sustava prema određenim vrstama kanalizacijskih sustava koje prevladavaju u dobivenim podacima – npr. samo za mješovite ili razdjelne sustave kanalizacije i sl.

Moguće je razviti određeni informacijski sustav na razini cijele Republike Hrvatske ili čak Europske unije gdje bi sva poduzeća koja upravljaju kanalizacijskim sustavima unosila pojedine karakteristike kanalizacijskih sustava, troškove održavanja za određeni period i dr. Takav način omogućio bi usporedbu kvalitete održavanja, troškova održavanja te, na kraju, izradu što točnijeg modela za procjenu troškova održavanja kanalizacijskog sustava.

POPIS LITERATURE

- [1] M. Šperac, D. Obradović, Odvodnja otpadnih voda alternativnim kondominijalnim kanalizacijskim sustavom, in *Proceedings of the 9th international natural gas, heat and water conference - PLIN 2018*, 2018, pp. 199–208.
- [2] S. Angel, J. Parent, D. L. Civico, M. A. Blei, *Atlas of Urban Expansion*. Cambridge MA: Lincoln Institute of Land Policy, 2012.
- [3] J. E. Fontecha, O. O. Guaje, D. Duque, R. Akhavan-Tabatabaei, J. P. Rodríguez, A. L. Medaglia, Combined maintenance and routing optimization for large-scale sewage cleaning, *Annals of Operations Research*, vol. 286, no. 1–2, pp. 441–474, 2020.
- [4] N. Počuča, *Ekohidrologija, zagađenje i zaštita voda*. Beograd: Građevinska knjiga, 2008.
- [5] I. Gudelj, Jedno od ključnih načela EU politike u području upravljanja vodom je pristup koji uključuje širu suradnju, *Hrvatske vode*, vol. 29, no. 115, pp. 47–49, 2021.
- [6] R. Karleuša, Problemi i promašaji u odvodnji, in *Odvodnja otpadnih i oborinskih voda - uvjet održivog razvoja*, 2004, pp. 113–121.
- [7] V. Trbojević, *Zaštita potrošača korisnika vodne usluge opskrbe vodom*, Zagreb, 2018.
- [8] United Nations and General Assembly, *Resolution adopted by the General Assembly on 28 July 2010*. 2010.
- [9] V. Oreščanin, R. Kollar, H. Crnojević, K. Nađ, I. Halkijević, M. Kuspilić, Pročišćavanje podzemnih voda s područja Vukovarsko-srijemske županije kombinacijom elektrokemijskih metoda i naprednih oksidacijskih procesa, *Hrvatske vode*, vol. 28, no. 118, pp. 173–182, 2020.
- [10] D. M. Frangopol, D. Saydam, S. Kim, Maintenance, management, life-cycle design and performance of structures and infrastructures: a brief review, *Structure and Infrastructure Engineering*, vol. 8, no. 1, pp. 1–25, 2012.
- [11] D. Kim, S. Yi, W. Lee, Life Cycle Assessment of Sewer System: Comparison of Pipe Materials, in *World Congress on Advances in Civil, Environmental and Materials Research (ACEM' 12)*, 2012, pp. 2963–2975.
- [12] Narodne novine, Službeni list Republike Hrvatske. *Zakon o kritičnim infrastrukturama*. (NN 56/13), 2013.
- [13] van M. C. M. Loosdrecht, H. P. Nielsen, M. C. Lopez-Vazquez, D. Brdjanovic, *Eksperimentalne metode u obradi otpadnih voda*. UK: IWA Publishing, 2016.
- [14] D. Kučić Grgić, L. Bera, M. Miloloža *et al.*, Obrada aktivnog mulja s uređaja za pročišćavanje komunalnih otpadnih voda procesom kompostiranja, *Hrvatske vode*, vol. 28, no. 111, pp. 1–8, 2020.
- [15] B. Kujundžić (ur.), *Kanalizacija Beograda 1905. -1975*. Beograd: NIP Export-press, 1975.
- [16] S. J. Tait, R. M. Ashley, A. Cashman, J. Blanksby, A. J. Saul, Sewer system operation into the 21st century, study of selected responses from a UK perspective, *Urban Water*

Journal, vol. 5, no. 1, pp. 79–88, 2008.

- [17] E. Vahidi, E. Jin, M. Das, M. Singh, F. Zhao, Environmental life cycle analysis of pipe materials for sewer systems, *Sustainable Cities and Society*, vol. 27, pp. 167–174, 2016.
- [18] B. Balaji, P. Mariappan, S. Senthamilkumar, Technology options for sewerage system, *Global Journal for Research Analysis*, vol. 3, no. 1, pp. 4–6, 2014.
- [19] A. Reznik, Y. Jiang, A. Dinar, The Impacts of Climate Change on Wastewater Treatment Costs: Evidence from the Wastewater Sector in China, *Water*, vol. 12, no. 11, p. 3272, 2020.
- [20] J. Guzmán-Fierro, C. Sharel, I. González *et al.*, Bayesian network-based methodology for selecting a cost-effective sewer asset management model, *Water Science and Technology*, 2020.
- [21] Narodne novine, Službeni list Republike Hrvatske, *Zakon o vodnim uslugama*. (NN 66/19), 2019.
- [22] Narodne novine, Službeni list Republike Hrvatske, *Zakon o vodama*. (NN 66/19), 2019.
- [23] Narodne novine, Službeni list Republike Hrvatske, *Zakon o izmjenama zakona o vodama*. (NN 84/21), 2021.
- [24] B. M. Jahić, *Prečišćavanje zagađenih voda*. Novi Sad: Naučno obrazovni institut za uređenje voda, Poljoprivredni fakultet, 1990.
- [25] B. Tušar, *Kućna kanalizacija*. Zagreb: Sveučilište u Zagrebu, Građevinski fakultet, 2001.
- [26] N. Ružinski, A. Anić Vučinić, *Obrada otpadnih voda biljnim uređajima*. Zagreb: Hrvatska sveučilišna naklada, 2010.
- [27] S. Marenjak, M. A. El-Haram, R. M. W. Horner, Procjena ukupnih troškova projekata u visokogradnji, *Građevinar*, vol. 54, no. 07, pp. 393–401, 2002.
- [28] A. Al-Hajj, M. W. Horner, Modelling the running costs of buildings, *Construction Management and Economics*, vol. 16, no. 4, pp. 459–470, 1998.
- [29] W. Du, J. Yu, Y. Gu, Y. Li, X. Han, Q. Liu, Preparation and application of microcapsules containing toluene-di-isocyanate for self-healing of concrete, *Construction and Building Materials*, vol. 202, pp. 762–769, 2019.
- [30] B. Van Belleghem, K. Van Tittelboom, N. De Belie, Efficiency of self-healing cementitious materials with encapsulated polyurethane to reduce water ingress through cracks, *Materiales de Construcción*, vol. 68, no. 330, 2018.
- [31] D. Gardner, R. Lark, T. Jefferson, R. Davies, A survey on problems encountered in current concrete construction and the potential benefits of self-healing cementitious materials, *Case Studies in Construction Materials*, vol. 8, pp. 238–247, 2018.
- [32] A. Danish, M. A. Mosaberpanah, M. Usama Salim, Past and present techniques of self-healing in cementitious materials: A critical review on efficiency of implemented treatments, *Journal of Materials Research and Technology*, vol. 9, no. 3, pp. 6883–6899, 2020.

- [33] A. N. Tafuri, A. Selvakumar, Wastewater collection system infrastructure research needs in the USA, *Urban Water*, vol. 4, no. 1, pp. 21–29, 2002.
- [34] United States General Accounting Office, WATER INFRASTRUCTURE Comprehensive Asset Management Has Potential to Help Utilities Better Identify Needs and Plan Future Investments, Washington, D.C., 2004.
- [35] B. Kujundžić, Kanalizacioni sistem - definicija, karakteristike, delovi i zadaci, in *Savremena eksploatacija i održavanje objekata i opreme vodovoda i kanalizacije*, B. Kujundžić (ur.), Beograd: Udruženje za tehnologiju vode i sanitarno inženjerstvo, 2010, pp. 345–354.
- [36] D. Obradović, Prevencija kvarova sprječavanjem rasta i uklanjanjem korijenja drveća u kanalizacijskim cijevima, *Vodoprivreda*, vol. 50, no. 291–293, pp. 165–173, 2018.
- [37] J. Marsalek, W. Schilling, Operation of sewer systems, in *Hydroinformatics Tools for Planning, Design, Operation and Rehabilitation of Sewer Systems*, 1998, pp. 393–414.
- [38] American Society of Civil Engineers (ASCE), 2021 Infrastructure Report Card, 2021.
- [39] American Society of Civil Engineers (ASCE), 2017 Infrastructure Report Card, 2017.
- [40] H. Matijević, M. Roić, P. Vojnović, Oblikovanje veza Facility Management i poslovnih informacijskih sustava, *Geodetski list*, vol. 61, no. 3, pp. 183–198, 2007.
- [41] Z. Vidić, Metode cjelovitog upravljanja objektima, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, 2011.
- [42] R. Filipović, *Englesko-hrvatski rječnik*, Drugo izdanje, Zagreb: Školska knjiga, 2004.
- [43] Ž. Bujas, *Veliki englesko-hrvatski rječnik*, Zagreb: Nakladni zavod Globus, 2001.
- [44] B. Bogнар, S. Marenjak, H. Krstić, Analiza stvarnih i planiranih troškova održavanja i uporabe građevina, *Electronic Journal of the Faculty of Civil Engineering Osijek - e-GFOS*, vol. 2, no. 3, pp. 85–96, 2011.
- [45] Z. Lacković, *Outsourcing u održavanju*. Osijek: Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski fakultet, 2014.
- [46] S. A. H. bin Syed Mustapa, K. Jusoff, Facility Management Challenges and Opportunities in the Malaysian Property Sector, *Journal of Sustainable Development*, vol. 1, no. 2, 2009.
- [47] D. Vugrinec, *Facility Management Handbook - Priručnik za upravljanje poslovnim zgradama*. Zagreb: 2G2E - Udruga za gospodarenje građevinama, energijsku efikasnost, promicanje znanja i vještina, 2012.
- [48] The International Facility Management Association, What is Facility Management, 2021. [Online]. Dostupno na: <https://www.ifma.org/about/what-is-facility-management>. (Pristupljeno 25.08.2021.).
- [49] E. Teicholz, *Facility Design and Management Handbook*. McGraw-Hill, 2004.
- [50] M. J. Wiggins, *Facilities Managers Desk Reference*. Chichester, West Sussex: John Wiley & Sons, 2010.
- [51] Y. C. Wijnia, P. M. Herder, The state of Asset Management in the Netherlands, in

-
- Engineering Asset Lifecycle Management*, London: Springer London, 2010, pp. 164–172.
- [52] F. Taillandier, S. M. Elachachi, A. Bennabi, A decision-support framework to manage a sewer system considering uncertainties, *Urban Water Journal*, vol. 17, no. 4, pp. 344–355, 2020.
- [53] B. Đorđević, *Cybernetics in water resources management*. Colorado, USA: Water Resources Publication, 1993.
- [54] M. Karić, *Mikroekonomika*, Dotiskano prvo izdanje. Osijek: Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku, 2009.
- [55] A. Čaušević, N. Rustempašić, *Rekonstrukcije zidanih objekata visokogradnje*. Sarajevo, Bosna i Hercegovina: Univerzitet u Sarajevu, Arhitektonski fakultet, 2014.
- [56] M. A. El-Haram, M. W. Horner, Factors affecting housing maintenance cost, *Journal of Quality in Maintenance Engineering*, vol. 8, no. 2, pp. 115–123, 2002.
- [57] Narodne novine, Službeni list Republike Hrvatske, *Zakon o gradnji*. (NN 153/13, 20/17, 39/19, 125/19). 2019.
- [58] A. Cerić, M. Katavić, Upravljanje održavanjem zgrada, *Građevinar*, vol. 53, no. 02, pp. 83–89, 2001.
- [59] S. Marenjak, H. Krstić, Analysis of buildings operation and maintenance costs, *Građevinar*, vol. 64, no. 4, pp. 293–303, 2012.
- [60] M. Aganović, *Urbana struktura stambenih naselja*. Sarajevo, Bosna i Hercegovina: Zavod za ekonomsko planiranje, 1980.
- [61] Z. Lacković, *Inženjerski menadžment*. Osijek: Sveučilište Josipa Jurja Strossmayera u Osijeku, Elektrotehnički fakultet u Osijeku, 2008.
- [62] Narodne novine, Službeni list Republike Hrvatske. *Pravilnik o održavanju građevina*. (NN 122/14, 98/19), 2019.
- [63] Narodne novine, Službeni list Republike Hrvatske, *Uredba o održavanju zgrada*. (NN 64/97), 1997.
- [64] D. Langdon, Life cycle costing (LCC) as a contribution to sustainable construction: a common methodology Final Report, London, UK, 2007.
- [65] G. Jiang, J. Keller, P. L. Bond, Z. Yuan, Predicting concrete corrosion of sewers using artificial neural network, *Water Research*, vol. 92, pp. 52–60, 2016.
- [66] O. Moselhi, T. Shehab-Eldeen, Automated detection of surface defects in water and sewer pipes, *Automation in Construction*, vol. 8, no. 5, pp. 581–588, 1999.
- [67] S. K. Sinha, P. W. Fieguth, Neuro-fuzzy network for the classification of buried pipe defects, *Automation in Construction*, vol. 15, no. 1, pp. 73–83, 2006.
- [68] H. D. Tran, B. J. C. Perera, A. W. M. Ng, Markov and Neural Network Models for Prediction of Structural Deterioration of Storm-Water Pipe Assets, *Journal of Infrastructure Systems*, vol. 16, no. 2, pp. 167–171, 2010.
- [69] D. H. Tran, A. W. M. Ng, B. J. C. Perera, Neural networks deterioration models for
-

-
- serviceability condition of buried stormwater pipes, *Engineering Applications of Artificial Intelligence*, vol. 20, no. 8, pp. 1144–1151, 2007.
- [70] D. H. Tran, A. W. M. Ng, B. J. C. Perera, S. Burn, P. Davis, Application of probabilistic neural networks in modelling structural deterioration of stormwater pipes, *Urban Water Journal*, vol. 3, no. 3, pp. 175–184, 2006.
- [71] V. Sousa, J. P. Matos, N. Matias, Evaluation of artificial intelligence tool performance and uncertainty for predicting sewer structural condition, *Automation in Construction*, vol. 44, pp. 84–91, 2014.
- [72] M. Najafi, G. Kulandaivel, Pipeline Condition Prediction Using Neural Network Models, in *Pipelines 2005*, 2005, pp. 767–781.
- [73] M. J. Chae, D. M. Abraham, Neuro-Fuzzy Approaches for Sanitary Sewer Pipeline Condition Assessment, *Journal of Computing in Civil Engineering*, vol. 15, no. 1, pp. 4–14, 2001.
- [74] J. Shen, W. Shen, J. Chang, N. Gong, Fuzzy Neural Network for Flow Estimation in Sewer Systems During Wet Weather, *Water Environment Research*, vol. 78, no. 2, pp. 100–109, 2006.
- [75] I. Ebtehaj, H. Bonakdari, Evaluation of Sediment Transport in Sewer using Artificial Neural Network, *Engineering Applications of Computational Fluid Mechanics*, vol. 7, no. 3, pp. 382–392, 2013.
- [76] D. P. Alex, M. Al Hussein, A. Bouferguene, S. Fernando, Artificial Neural Network Model for Cost Estimation: City of Edmonton's Water and Sewer Installation Services, *Journal of Construction Engineering and Management*, vol. 136, no. 7, pp. 745–756, 2010.
- [77] Wen-xiang Peng, Rong Jia, Improved genetic algorithms for optimal design of drainage systems, in *ICARCV 2004 8th Control, Automation, Robotics and Vision Conference, 2004.*, 2004, vol. 1, pp. 227–231.
- [78] M. D. Yang, T. C. Su, Automation model of sewerage rehabilitation planning, *Water Science and Technology*, vol. 54, no. 11–12, pp. 225–232, 2006.
- [79] M. Yang, T. Su, An optimization model of sewage rehabilitation, *Journal of Chinese Institute of Engineers*, vol. 30, no. 4, pp. 651–659, 2007.
- [80] M. R. Halfawy, L. Dridi, S. Baker, Integrated Decision Support System for Optimal Renewal Planning of Sewer Networks, *Journal of Computing in Civil Engineering*, vol. 22, no. 6, pp. 360–372, 2008.
- [81] L. Berardi, O. Giustolisi, D. A. Savic, Z. Kapelan, An effective multi-objective approach to prioritisation of sewer pipe inspection, *Water Science and Technoogy*, vol. 60, no. 4, pp. 841–850, 2009.
- [82] S. Van Vuuren, Application of genetic algorithms - Determination of the optimal pipe diameters, *Water SA*, vol. 28, no. 2, 2002.
- [83] R. M. Afshar, Application of a Genetic Algorithms - Determination of the optimal pipe diameters, *Scientia Iranica*, vol. 28, no. 3, 2006.
- [84] B. Ward, D. A. Savić, A multi-objective optimisation model for sewer rehabilitation
-

- considering critical risk of failure, *Water Science and Technology*, vol. 66, no. 11, pp. 2410–2417, 2012.
- [85] L. Ortolano, G. Le Coeur, R. MacGilchrist, Expert System for Sewer Network Maintenance: Validation Issues, *Journal of Computing in Civil Engineering*, vol. 4, no. 1, pp. 37–54, 1990.
- [86] W. Ben Tagherout, S. Bennis, J. Bengassem, A Fuzzy Expert System for Prioritizing Rehabilitation of Sewer Networks, *Computer-Aided Civil and Infrastructure Engineering*, vol. 26, no. 2, pp. 146–152, 2011.
- [87] M. Hahn, R. N. Palmer, M. S. Merrill, Prioritizing Sewer Line Inspection with an Expert System, in *WRPMD '99*, 1999, pp. 1–9.
- [88] M. A. Hahn, R. N. Palmer, M. S. Merrill, A. B. Lukas, Expert System for Prioritizing the Inspection of Sewers: Knowledge Base Formulation and Evaluation, *Journal of Water Resources Planning and Management*, vol. 128, no. 2, pp. 121–129, 2002.
- [89] E. J. Ana, W. Bauwens, Sewer Network Asset Management Decision-Support Tools: A Review, in *International Symposium on New Directions in Urban Water Management*, 2007, pp. 1–8.
- [90] M. Giovanelli, M. Maglionico, Identification of the optimal level of service sewer networks by means of expert procedure, in *11th International Conference on Urban Drainage, Edinburgh, Scotland*, 2008, pp. 1–10.
- [91] R. R. Harvey, E. A. McBean, Comparing the utility of decision trees and support vector machines when planning inspections of linear sewer infrastructure, *Journal of Hydroinformatics*, vol. 16, no. 6, pp. 1265–1279, 2014.
- [92] E. V. Ana, W. Bauwens, Modeling the structural deterioration of urban drainage pipes: the state-of-the-art in statistical methods, *Urban Water Journal*, vol. 7, no. 1, pp. 47–59, 2010.
- [93] R. Wirahadikusumah, D. M. Abraham, J. Castello, Markov decision process for sewer rehabilitation, *Engineering, Construction and Architectural Management*, vol. 6, no. 4, pp. 358–370, 1999.
- [94] M. Marzouk, M. Omar, Multiobjective optimisation algorithm for sewer network rehabilitation, *Structure and Infrastructure Engineering*, vol. 9, no. 11, pp. 1094–1102, 2013.
- [95] T. Micevski, G. Kuczera, P. Coombes, Markov Model for Storm Water Pipe Deterioration, *Journal of Infrastructure Systems*, vol. 8, no. 2, pp. 49–56, 2002.
- [96] H. S. Baik, D. Abraham, D. J. Gipson, Impacts of Deterioration Based Life Cycle Cost Analysis (LCCA) on the Assessment of Values of Wastewater Infrastructure Assets, in *Pipeline Engineering and Construction: What's on the Horizon? Proceedings of the Pipelines 2004 International Conference*, 2004, pp. 1–10.
- [97] S.-H. Chung, T.-H. Hong, S.-W. Han, J.-H. Son, S.-Y. Lee, Life cycle cost analysis based optimal maintenance and rehabilitation for underground infrastructure management, *KSCE Journal of Civil Engineering*, vol. 10, no. 4, pp. 243–253, 2006.
- [98] D. M. Abraham, R. Wirahadikusumah, T. J. Short, S. Shahbahrani, Optimization

-
- Modeling for Sewer Network Management, *Journal of Construction Engineering and Management*, vol. 124, no. 5, pp. 402–410, 1998.
- [99] H.-S. Baik, H. S. Jeong, D. M. Abraham, Estimating Transition Probabilities in Markov Chain-Based Deterioration Models for Management of Wastewater Systems, *Journal of Water Resources Planning and Management*, vol. 132, no. 1, pp. 15–24, 2006.
- [100] S. Tayefeh Hashemi, O. M. Ebadati, H. Kaur, Cost estimation and prediction in construction projects: a systematic review on machine learning techniques, *SN Applied Sciences*, vol. 2, no. 10, p. 1703, 2020.
- [101] CPHEEO, *Manual on Sewerage and Sewage Treatment Systems*. Ministry of Urban Development, New Delhi; Central Public Health and Environmental Engineering Organization in collaboration with Japan International Cooperation Agency, 2013.
- [102] B. C. Paulson, Designing to Reduce Construction Costs, *Journal of the Construction Division*, vol. 102, no. 4, pp. 587–592, 1976.
- [103] H. Krstić, Model procjene troškova održavanja i uporabe građevina na primjeru građevina Sveučilišta Josipa Jurja Strossmayera u Osijeku, Sveučilište J. J. Strossmayera u Osijeku, Građevinski fakultet Osijek, 2011.
- [104] R. P. Waier, C. S. Plotner, Chapter 15 - Maintenance & Repair Estimating, in *RS Means: Cost Planning & Estimating for Facilities Maintenance*, R. P. Waier, C. S. Plotner, S. Morris, Eds. Hoboken, New Jersey: John Wiley & Sons, 1996, pp. 231–251.
- [105] B. Wood, *Building Care*. Oxford, UK: Blackwell Science Ltd, 2003.
- [106] A. M. A. Aziz, Performance Analysis and Forecasting for WSDOT Highway Projects, Seattle, Washington, 2007.
- [107] F. K. T. Cheung, M. Skitmore, Application of cross validation techniques for modelling construction costs during the very early design stage, *Building and Environment*, vol. 41, no. 12, pp. 1973–1990, 2006.
- [108] Y. Liu, A forecasting model for maintenance and repair costs for office buildings, Concordia University, Montreal, Quebec, Canada, 2006.
- [109] A. A. Shah, F. Ahmad, C. Peng Au-Yong, Office building maintenance: Cost prediction model, *Građevinar*, vol. 65, no. 9, pp. 803–809, 2013.
- [110] H. Krstić, S. Marenjak, Maintenance and operation costs model for university buildings, *Tehnički vjesnik*, vol. 24, no. Supplement 1, 2017.
- [111] C.-K. Lee, Y.-I. Jeon, A maintenance cost prediction model for elementary schools by correcting FM budget history and performance data, *International Journal of Application or Innovation in Engineering & Management*, vol. 6, no. 5, pp. 084–094, 2017.
- [112] A. H. Boussabaine, R. J. Kirkham, Simulation of maintenance costs in UK local authority sport centres, *Construction Management and Economics*, vol. 22, no. 10, pp. 1011–1020, 2004.
- [113] J.-M. Kim, T. Kim, Y.-J. Yu, K. Son, Development of a Maintenance and Repair Cost Estimation Model for Educational Buildings Using Regression Analysis, *Journal of Asian Architecture and Building Engineering*, vol. 17, no. 2, pp. 307–312, 2018.
-

-
- [114] S. Mahmoud, M. F. Khamidi, A. Idrus, O. Abdul-Lateef Ashola, Development of Maintenance Cost Prediction Model for Heritage Buildings, *Jurnal Teknologi*, vol. 74, no. 2, 2015.
- [115] T. J. Nipp, Development of a Mathematical Model for the Estimation of Required Maintenance for a Homogenous Facilities Portfolio Using Multiple Linear Regression, University of Tennessee, 2017.
- [116] K. Tijanić Štrok, Razvoj modela za učinkovito upravljanje održavanjem javnih obrazovnih građevina, Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek, 2021.
- [117] M. Bouabaz, R. M. W. Horner, Modelling and Predicting Bridge Repair and Maintenance Costs, in *Bridge Management*, Boston, MA: Springer US, 1990, pp. 187–197.
- [118] X. Shi, B. Zhao, Y. Yao, F. Wang, Prediction Methods for Routine Maintenance Costs of a Reinforced Concrete Beam Bridge Based on Panel Data, *Advances in Civil Engineering*, vol. 2019, pp. 1–12, 2019.
- [119] C.-S. Li, S.-J. Guo, Development of a Cost Predicting Model for Maintenance of University Buildings, 2012, pp. 215–221.
- [120] C.-S. Li, S.-J. Guo, Life Cycle Cost Analysis of Maintenance Costs and Budgets for University Buildings in Taiwan, *Journal of Asian Architecture and Building Engineering*, vol. 11, no. 1, pp. 87–94, 2012.
- [121] M. Bouabaz, M. Hamami, A Cost Estimation Model for Repair Bridges Based on Artificial Neural Network, *American Journal of Applied Sciences*, vol. 5, no. 4, pp. 334–339, 2008.
- [122] A. Asadi, A. Hadavi, R. J. Krizek, Bridge Life-Cycle Cost Analysis Using Artificial Neural Networks, in *Proceedings of the CIB W78-W102 2011: International Conference*, 2011.
- [123] I. Gudac Hodanić, Model procjene troškova životnog ciklusa pontona kao podrška sustavu upravljanja marinama, Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek, 2020.
- [124] G. Lofrano, J. Brown, Wastewater management through the ages: A history of mankind, *Science of the Total Environment*, vol. 408, no. 22, pp. 5254–5264, 2010.
- [125] H. S. Vuorinen, P. S. Juuti, T. S. Katko, History of water and health from ancient civilizations to modern times, *Water Supply*, vol. 7, no. 1, pp. 49–57, 2007.
- [126] K. Kosić, (ur.), *Kanalizacija 1892. - 1992*. Zagreb: Javno poduzeće “Kanalizacija” Zagreb, Zagreb, 1992.
- [127] B. Harris, J. Helgertz, Urban sanitation and the decline of mortality, *The History of the Family*, vol. 24, no. 2, pp. 207–226, 2019.
- [128] A. Hinde, B. Harris, Mortality decline by cause in urban and rural England and Wales, 1851–1910, *The History of the Family*, vol. 24, no. 2, pp. 377–403, 2019.
- [129] R. Dillingham, R. L. Guerrant, Childhood stunting: measuring and stemming the staggering costs of inadequate water and sanitation, *Lancet*, vol. 363, no. 9403, pp. 94–
-

- 95, 2004.
- [130] L. Cain, E. Rotella, Death and spending: urban mortality and municipal expenditure on sanitation, *Annales de Démographie Historique*, vol. 1, no. 101, pp. 139–154, 2001.
- [131] Z. Kos, *Vodoprivreda gornjeg Jadrana: povijest vodnoga graditeljstva na vodnom području Primorsko-istarskih slivova, II. Kanalizacijski sustavi, Knjiga 1. Istarska županija*. Rijeka: Adamić, 2006.
- [132] M. Alić, Otpadne vode kroz povijest, *Hrvatska vodoprivreda*, vol. XXV, no. 218, pp. 100–104, 2017.
- [133] S. Kružić, *Evakuacija, kondicioniranje i dispozicija otpadnih voda*. Rijeka: Sveučilište u Rijeci, Fakultet graditeljskih znanosti, 1981.
- [134] J. Zrnić, P. Zrnić, *Tehničar 5 građevinski priručnik*. Beograd: Građevinska knjiga, 1979.
- [135] A. N. Angelakis, E. Kavoulaki, E. G. Dialynas, Sanitation and wastewater technologies in Minoan Era, in *Evolution of Sanitation and Wastewater Technologies through the Centuries*, J. B. Rose and A. N. Angelakis, Eds. London, UK: IWA Publishing, 2014.
- [136] S. Grozdanović, Hidrotehnička infrastruktura Starorimskog Viminacijuma, *Vodoprivreda*, vol. 47, no. 273–275, pp. 141–147, 2015.
- [137] J. Rubeša, Kanalizacija Grada Pariza, *Hrvatske vode*, vol. 26, no. 106, pp. 293–300, 2018.
- [138] I. Žile, Srednjovjekovna kanalizacija grada Dubrovnika, *Starohrvatska prosvjeta*, vol. 3, no. 34, pp. 437–449, 2007.
- [139] K. Marasović, S. Perojević, J. Margeta, Roman sewer of Diocletian's palace in Split, *Građevinar*, vol. 66, no. 3, pp. 237–249, 2014.
- [140] Z. Živaković Kerže, *Voda i grad: Povijest vodoopskrbe grada Osijeka*. Osijek: Hrvatski institut za povijest, Podružnica za povijest Slavonije, Srijema i Baranje, Slavonski Brod, Vodovod-Osijek d.o.o, 2007.
- [141] Z. Tadić, Suvremene metode projektiranja kanalizacijskih sustava, in *Odvodnja otpadnih i oborinskih voda - uvjet održivog razvoja*, 2005, pp. 35–49.
- [142] V. Simović, (ur.), *Leksikon građevinarstva*. Zagreb: Masmedia, 2002.
- [143] Projektiranje sustava odvodnje (kanalizacijskih sustava). 2018. [Online]. Dostupno na: <http://www.grad.hr/nastava/hidrotehnika/gf/odvodnja/vjezbe/Projektiranje%20sustava%20odvodnje%20-%20za%20web.pdf> (Pristupljeno 10.08.2021.).
- [144] M. Radonić, *Vodovod i kanalizacija u zgradama*. Beograd: Građevinska knjiga, 1983.
- [145] G. Balacco, V. Iacobellis, F. Portincasa, E. Ragno, V. Totaro, A. F. Piccinni, Analysis of a Large Maintenance Journal of the Sewer Networks of Three Apulian Provinces in Southern Italy, *Water*, vol. 12, no. 5, p. 1417, 2020.
- [146] J. Margeta, *Kanalizacija naselja*. Split, Osijek, Zagreb: Građevinski fakultet Sveučilišta u Splitu, Građevinski fakultet Sveučilišta J. J. Strossmayera u Osijeku, Institut građevinarstva Hrvatske, 1998.
- [147] P. Uskoković, Osnovne karakteristike sistema za snabdevanje vodom i odvođenje

- otpadnih voda bitnih za razmatranje njihovog održavanja, in *Savremena eksploatacija i održavanje objekata i opreme vodovoda i kanalizacije*, B. Kujundžić, (ur.). Beograd: Udruženje za tehnologiju vode i sanitarno inženjerstvo, 2010, pp. 79-101.
- [148] J. Margeta, *Oborinske i otpadne vode: teret onečišćenja, mjere zaštite*. Split: Sveučilište u Splitu, Građevinsko-arhitektonski fakultet, 2007.
- [149] A. Botturi, Ozbayram E. G., Tondera, K. *et al.*, Combined sewer overflows: A critical review on best practice and innovative solutions to mitigate impacts on environment and human health, *Critical Reviews in Environmental Science and Technology*, pp. 1–34, 2020.
- [150] J. Margeta, Kontrola negativnih utjecaja preljevniha voda kanalizacije, *Građevinar*, vol. 63, no. 7, pp. 651–660, 2011.
- [151] Vrste otpadnih voda, 2018. [Online]. Dostupno na: http://www.grad.hr/nastava/hidrotehnika/gf/odvodnja/predavanja/ODVODNJA_1.pdf. (Pristupljeno 20.07.2021.).
- [152] A. R. Reed, *Sustainable Sewerage: Guidelines for Community Schemes*. London, UK: Intermediate Technology Publications & Water, Engineering and Development Centre, 1995.
- [153] B. Kurpjel, *Osnovi hidrotehnike, II dio*. Sarajevo, Bosna i Hercegovina: Građevinski fakultet Sarajevo, 1985.
- [154] J. A. Tarr, The Separate vs. Combined Sewer Problem, *Journal of Urban History*, vol. 5, no. 3, pp. 308–339, 1979.
- [155] B. Blagojević, *Vodovod i kanalizacija sa propisima i standardima*, 3. dopunjeno izdanje. Beograd: Tehnička knjiga, 2002.
- [156] G. Polančec, M. Šperac, Rješenje kanalizacije naselja, *Electronic Journal of the Faculty of Civil Engineering Osijek -e-GFOS*, vol. 2, no. 2, pp. 89–100, 2011.
- [157] J. Marsalek, Challenges in urban drainage, in *Hydroinformatics Tools for Planning, Design, Operation and Rehabilitation of Sewer Systems*, 1998, pp. 1–24.
- [158] I. Hrskanović, Održavanje sustava odvodnje naselja, Sveučilište J. J. Strossmayera u Osijeku, Građevinski fakultet Osijek, 2016.
- [159] D. Ljubisavljević, M. Obrenović, Nestandardni kanalizacioni sistemi: vakumska kanalizacija i kanalizacija pod pritiskom, *Vodoprivreda*, vol. 42, no. 246–248, pp. 237–244, 2010.
- [160] A. Scott, The Liernur system at Amsterdam, *Journal of the Society of Arts*, p. 671, 1876.
- [161] D. Obradović, M. Šperac, S. Marenjak, Maintenance issues of the vacuum sewer system, *Environmental Engineering*, vol. 6, no. 2, pp. 40–48, 2019.
- [162] M. Duncan, A. Sleight, K. Tayler, *PC-Based Simplified Sewer Design*. Leeds: School of Civil Engineering, University of Leeds, 2001.
- [163] L. Runko Luttenberger, Prilog uspostavi decentraliziraniha sustava otpadnih voda, *Pomorski zbornik*, vol. 40, no. 1, pp. 553–560, 2002.

- [164] G. Öberg, G. S. Metson, Y. Kuwayama, S. A. Conrad, Conventional Sewer Systems Are Too Time-Consuming, Costly and Inflexible to Meet the Challenges of the 21st Century, *Sustainability*, vol. 12, no. 16, p. 6518, Aug. 2020.
- [165] Narodne novine, Službeni list Republike Hrvatske, *Pravilnik o tehničkim zahtjevima za građevine odvodnje otpadnih voda, kao i rokovima obvezne kontrole ispravnosti građevina odvodnje i pročišćavanja otpadnih voda*. (NN 3/11), 2011.
- [166] M. Malek Mohammadi, M. Najafi, S. Kermanshachi, V. Kaushal, R. Serajiantehrani, Factors Influencing the Condition of Sewer Pipes: State-of-the-Art Review, *Journal of Pipeline Systems Engineering and Practice*, vol. 11, no. 4, p. 03120002, 2020.
- [167] A. Hawari, F. Alkadour, M. Elmasry, T. Zayed, A state of the art review on condition assessment models developed for sewer pipelines, *Engineering Applications of Artificial Intelligence*, vol. 93, p. 103721, 2020.
- [168] X. Yin, Y. Chen, A. Bouferguene, M. Al-Hussein, Data-driven bi-level sewer pipe deterioration model: Design and analysis, *Automation in Construction*, vol. 116, p. 103181, 2020.
- [169] T. Laakso, T. Kokkonen, I. Mellin, R. Vahala, Sewer Life Span Prediction: Comparison of Methods and Assessment of the Sample Impact on the Results, *Water*, vol. 11, no. 12, p. 2657, 2019.
- [170] D. M. Abraham, Life Cycle Cost Integration for the Rehabilitation of Wastewater Infrastructure, in *Construction Research Congress*, 2003, pp. 1–9.
- [171] H. Plihal, F. Kretschmer, D. Schwarz, T. Ertl, Innovative sewer inspection as a basis for an optimised condition-based maintenance strategy, *Water Practice and Technology*, vol. 9, no. 1, pp. 88–94, 2014.
- [172] D. Blažević, Predviđanje održavanja tehničkog sustava procjenom stanja, Sveučilište Josipa Jurja Strossmayera u Osijeku, Elektrotehnički fakultet Osijek, 2012.
- [173] L. J. Bond, Predictive Engineering for Aging Infrastructure, in *SPIE Conference on Nondestructive Evaluation of Utilities and Pipelines*, 1999, pp. 2–13.
- [174] L. Aihua, A method for condition evaluation based on DSMT, in *2010 2nd IEEE International Conference on Information Management and Engineering*, 2010, pp. 263–266.
- [175] L. Mann, A. Saxena, G. M. Knapp, Statistical-based or condition-based preventive maintenance?, *Journal of Quality in Maintenance Engineering*, vol. 1, no. 1, pp. 46–59, 1995.
- [176] G. M. Ujjan, M. Ali Taur, B. K. Lashari, Operation and Maintenance Cost of Drainage System: Tha Case Study of Bareji Distributary, Mirpurkhas, Sindh, Pakistan, in *National seminar on: Drainage in Pakistan*, 2000, pp. 101–104.
- [177] M. Šperac, V. Moser, T. Stvorić, Održavanje kanalizacijskog sustava uz primjenu GIS-a, *Electronic Journal of the Faculty of Civil Engineering Osijek - e-GFOS*, vol. 3, no. 5, pp. 86–94, 2012.
- [178] D. Obradović, A short review: Techniques for trenchless sewer rehabilitation, in *Young Scientist 2018*, 2018, pp. 1–8.

-
- [179] D. Obradović, M. Šperac, S. Marenjak, Possibilities of using expert methods for sewer system maintenance optimisation, *Građevinar*, vol. 71, no. 09, pp. 769–779, 2019.
- [180] M. J. Anbari, M. Tabesh, A. Roozbahani, Risk assessment model to prioritize sewer pipes inspection in wastewater collection networks, *Journal of Environmental Management*, vol. 190, pp. 91–101, 2017.
- [181] A. Robles-Velasco, P. Cortés, J. Muñuzuri, L. Onieva, Estimation of a logistic regression model by a genetic algorithm to predict pipe failures in sewer networks, *OR Spectrum*, 2021.
- [182] J. Ruwanpura, S. T. Ariaratnam, and A. El-assaly, Prediction models for sewer infrastructure utilizing rule-based simulation, *Civil Engineering and Environmental Systems*, vol. 21, no. 3, pp. 169–185, 2004.
- [183] S. T. Ariaratnam, C. W. MacLeod, Financial Outlay Modeling for a Local Sewer Rehabilitation Strategy, *Journal of Construction Engineering and Management*, vol. 128, no. 6, pp. 486–495, 2002.
- [184] M. Dilber, Eksploatacija i održavanje kanalizacione mreže, in *Savremena eksploatacija i održavanje objekata i opreme vodovoda i kanalizacije*, Beograd: Udruženje za tehnologiju vode i sanitarno inženjerstvo, 2010, p. 373.
- [185] H. Zaman, A. Bouferguene, M. Al-Hussein, C. Lorentz, Improving the productivity of drainage operations activities through schedule optimisation, *Urban Water Journal*, vol. 14, no. 3, pp. 298–306, 2017.
- [186] D. Malus, D. Kovačević, D. Vouk, Razmak okana na kanalizacijskoj mreži, *Građevinar*, vol. 60, no. 3, pp. 213–218, 2008.
- [187] M. Šperac, I. Hrskanović, Ž. Šreng, Održavanje gravitacijskih kanalizacijskih sustava, in *26. Međunarodni znanstveno-stručni skup Organizacija i tehnologija održavanja - OTO 2017. - Zbornik radova*, 2017, pp. 125–131.
- [188] J. Marsalek, W. Schilling, Operation of Sewer Systems, in *Hydroinformatics Tools for Planning, Design, Operation and Rehabilitation of Sewer Systems*, Dordrecht: Springer Netherlands, 1998, pp. 393–414.
- [189] I. Milojković, J. Despotović, I. Karanović, Model for maintenance of sewerage system based on inspection, in *IWA 7 th Eastern European Young Water Professionals Conference*, 2015, pp. 538–543.
- [190] I. Milojković, J. Despotović, M. Popović, Sewer System Inspection and Maintenance Model for Groundwater Protection, *Water Research and Management*, vol. 6, no. 3, pp. 29–34, 2016.
- [191] R. Wirahadikusumah, D. Abraham, T. Iseley, Challenging Issues in Modeling Deterioration of Combined Sewers, *Journal of Infrastructure Systems*, vol. 7, no. 2, pp. 77–84, 2001.
- [192] S. Khazraeializadeh, L. F. Gay, A. Bayat, Comparative analysis of sewer physical condition grading protocols for the City of Edmonton, *Canadian Journal of Civil Engineering*, vol. 41, no. 9, pp. 811–818, 2014.
- [193] M. Malek Mohammadi, M. Najafi, N. Salehabadi, R. Serajiantehrani, V. Kaushal,
-

-
- Predicting Condition of Sanitary Sewer Pipes with Gradient Boosting Tree, in *Pipelines 2020*, 2020, pp. 80–89.
- [194] D. E. Bauer, 15 Year Old Polyvinyl Chloride (PVC) Sewer Pipe; A Durability and Performance Review, in *Buried Plastic Pipe Technology*, 100 Barr Harbor Drive, West Conshohocken, PA 19428-2959: ASTM International, 1990, pp. 393-393–9.
- [195] H. Meerman, Lifetime Expectancy of PVC-U pipelines for sewer systems, in *International Conference Plastics Pipes XIV*, 2008.
- [196] Institute for Environmental Research & Environment, Life Cycle Assessment of PVC Water and Sewer Pipe and Comparative Sustainability Analysis of Pipe Materials, 2017.
- [197] C. Omana, R. Thorson, Future wastewater infrastructure needs and capital costs, Saint Paul, Minnesota, 2019.
- [198] *Prevention and Control of Sewer System Overflows*, Third edition. Virginia, USA: Water Environment Federation (WEF), 2011.
- [199] Y. Le Gat, Modelling the deterioration process of drainage pipelines, *Urban Water Journal*, vol. 5, no. 2, pp. 97–106, 2008.
- [200] Emerson Electric Co. and Ridgid, Cable Tools. RIDGID.com, pp. 20–21, 2021. [Online]. Dostupno na: <https://cdn2.ridgid.com/resources/media?key=d3f41178-3340-4bf6-8e05-ba967a79d31c&languageCode=en&type=document> (Pristupljeno 02.07.2021.).
- [201] D. E. Hoffman, S. G. Buchberger, M. U. Flanders, Preventing Sewer Blowouts during High-Velocity Jet Cleaning Operations, *Journal of Infrastructure Systems*, vol. 16, no. 4, pp. 273–281, 2010.
- [202] AQUATECHN.COM, Pregled tehnika profesionalnog čišćenja kanalizacije, 2021. [Online]. Dostupno na: <https://aquatechn.com/hr/kanalizacija/drugoe/metody-prochistki-kanalizacii.html>. (Pristupljeno 25.07.2021.).
- [203] Kaiser AG, Kaiser ECO 3.0, 2021. [Online]. Dostupno na: https://www.kaiser.li/fileadmin/user_upload/products/gallery/Eco_3.0/Kaiser_Produktfoelder_ECO3_EN_180418_web.pdf (Pristupljeno 23.07.2021.).
- [204] P. Svihra, Ranking of trees according to damage of sewage pipes, *Ornamental Northwest Archives*, vol. 11, no. 1, p. 7, 1987.
- [205] T. B. Randrup, E. G. McPherson, L. R. Costello, Tree Root Intrusion in Sewer Systems: Review of Extent and Costs, *Journal of Infrastructure Systems*, vol. 7, no. 1, pp. 26–31, 2001.
- [206] I. Lukić, H. Veledar, Deratizacija kanalizacijske mreže, in *Odvodnja otpadnih i oborinskih voda - uvjet održivog razvoja*, 2004, pp. 123–129.
- [207] J. M. Makar, Diagnostic Techniques for Sewer Systems, *Journal of Infrastructure Systems*, vol. 5, no. 2, pp. 69–78, 1999.
- [208] M. R. Halfawy, J. Hengmeechai, Efficient Algorithm for Crack Detection in Sewer Images from Closed-Circuit Television Inspections, *Journal of Infrastructure Systems*, vol. 20, no. 2, p. 04013014, 2014.
-

- [209] S. C. Feeney, S. Thayer, M. Bonomo, K. Martel, White Paper on Condition Assessment of Wastewater Collection Systems, Cincinnati, Ohio, 2009.
- [210] C. J. Thomson, P. Hayward, G. Hazelden *et al.*, *An Examination of Innovative Methods Used in the Inspection of Wastewater Collection Systems*. London, United Kingdom: WERF: Alexandria, VA and IWA Publishing, 2004.
- [211] T. Lampola, S. Kuikka, *Condition Assessment and Sewer Inspection (CASI) Methods - Guide Book*. Helsinki, Finska: Finnish Water Utilities Association, 2019.
- [212] S. Morera, C. Remy, J. Comas, L. Corominas, Life cycle assessment of construction and renovation of sewer systems using a detailed inventory tool, *The International Journal of Life Cycle Assessment*, vol. 21, no. 8, pp. 1121–1133, 2016.
- [213] D. Piškorić, Primjena višekriterijske analize pri izboru načina obnavljanja kanalizacijskih cjevovoda, *Građevinar*, vol. 59, no. 5, pp. 407–412, 2007.
- [214] E. Ellouche, S. Alam, R. Sterling, W. Condir, J. Matthews, National Database Structure for Life Cycle Performance Assessment of Water and Wastewater Rehabilitation Technologies (Retrospective Evaluation), Cincinnati, Ohio, USA, 2014.
- [215] United States Environmental Protection Agency, Collection Systems O&M Fact Sheet: Trenchless Sewer Rehabilitation, Washington, DC, 1999.
- [216] G. R. Koerner, R. M. Koerner, Geosynthetic use in trenchless pipe remediation and rehabilitation, *Geotextiles and Geomembranes*, vol. 14, no. 3–4, pp. 223–237, 1996.
- [217] N. B. Basu, A. Dey, D. G., Kolkata's brick sewer renewal: history, challenges and benefits, *Proceedings of the Institution of Civil Engineers - Civil Engineering*, vol. 166, no. 2, pp. 74–81, 2013.
- [218] M. Atchison, The Importance of Sanitary Sewer Maintenance, *Illinois municipal review*, pp. 21–22, 2012.
- [219] R. A. Fenner, Approaches to sewer maintenance: a review, *Urban Water*, vol. 2, no. 4, pp. 343–356, 2000.
- [220] D. Aničić, *Planiranje uporabnog vijeka građevina (prijevod norma niza ISO 15686 s autorskim uvodom i komentarima)*. Zagreb: Hrvatski savez građevinskih inženjera, 2004.
- [221] Hrvatske vode, *Strategija upravljanja vodama*. Zagreb: Hrvatske vode, 2009.
- [222] Narodne novine, Službeni list Republike Hrvatske, *Strategija upravljanja vodama*. (NN 91/08), 2008.
- [223] Narodne novine, Službeni list Republike Hrvatske, *Plan upravljanja vodnim područjima 2016. - 2021.* (NN 66/16), 2016.
- [224] Državni zavod za statistiku Republike Hrvatske, Tablica 2A - Godišnji strukturno-poslovni pokazatelji poduzeća prema NKD-u 2007. za djelatnosti Industrije (područja B do E, NKD 2007.), Zagreb, 2021.
- [225] Narodne novine, Službeni list Republike Hrvatske, *Odluka o nacionalnoj klasifikaciji djelatnosti 2007. - NKD 2007.* (NN 58/07), 2007.

-
- [226] The World Bank and IAWD, Water and Wastewater Services in the Danube Region, Albania Country Note, A State of the Sector, 2015.
- [227] The World Bank; IAWD, Water and Wastewater Services in the Danube Region, A State of the Sector, Regional Report, 2015.
- [228] The World Bank; IAWD, Water and Wastewater Services in the Danube Region, Slovakia Country Note, A State of the Sector, 2015.
- [229] The World Bank; IAWD, Water and Wastewater Services in the Danube Region, Slovenia Country Note, A State of the Sector, 2015.
- [230] D. Obradović, M. Šperac, S. Marenjak, Pristup uslugama vodoopskrbe i odvodnje, in *Zbornik radova GEO-EXPO 2020*, 2020, pp. 10–16.
- [231] The World Bank; IAWD, Water and Wastewater Services in the Danube Region, A State of the Sector 2018 Update, Report, 2019.
- [232] The World Bank; IAWD, Water and Wastewater Services in the Danube Region, Austria Country Note, A State of the Sector, 2015.
- [233] The World Bank; IAWD, Water and Wastewater Services in the Danube Region, Bulgaria Country Note, A State of the Sector, 2015.
- [234] The World Bank; IAWD, Water and Wastewater Services in the Danube Region, Hrvatska kratko izvješće o zemlji, Stanje sektora, 2015.
- [235] The World Bank; IAWD, Water and Wastewater Services in the Danube Region, Informacija o Bosni i Hercegovini, Stanje u sektoru, 2015.
- [236] The World Bank; IAWD, Water and Wastewater Services in the Danube Region, Kratak izveštaj za Srbiju, Stanje u sektoru, 2015.
- [237] The World Bank; IAWD, Water and Wastewater Services in the Danube Region, Montenegro Country Note, A State of the Sector, 2015.
- [238] The World Bank; IAWD, Water and Wastewater Services in the Danube Region, Romania Country Note, A State of the Sector, 2015.
- [239] Državni zavod za statistiku Republike Hrvatske, Tablica 1.3. Mreža javne odvodnje i uređaji za pročišćavanje otpadnih voda, Zagreb, 2021.
- [240] Državni zavod za statistiku Republike Hrvatske, Tabela 1.1. Podrijetlo, pročišćavanje i ispuštanje otpadnih voda, tis. m³, Zagreb, 2022.
- [241] Narodne novine, Službeni list Republike Hrvatske, *Pravilnik o posebnim uvjetima za obavljanje djelatnosti javne odvodnje*. (NN 28/11, 16/14), 2014.
- [242] B. Medanić, I. Pšunder, V. Skendrović, *Neki aspekti financiranja i financijskog odlučivanja u građevinarstvu*. Osijek: Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski fakultet, 2005.
- [243] K. Čulo, *Ekonomika investicijskih projekata*. Osijek: Građevinski fakultet Osijek, 2010.
- [244] C. J. Van Horne, M. J. Wachowicz, *Osnove financijskog menadžmenta*, Trinaesto izdanje. MATE d.o.o. Zagreb, ZSEM, 2014.
-

-
- [245] D. Salvatore, *Ekonomija za menadžere u svjetskoj privredi*. Zagreb: MATE d.o.o. Zagreb, 1994.
 - [246] A. P. Samuelson, D. W. Nordhaus, *Ekonomija*, Petnaesto izdanje. Zagreb: MATE d.o.o. Zagreb, 2000.
 - [247] Hrvatska narodna banka, Tablica F1: Aktivne kamatne stope Hrvatske narodne banke, Zagreb, 2021.
 - [248] Narodne novine, Službeni list Republike Hrvatske, *Odluka o kamatnim stopama, diskontnoj (eskontnoj) stopi i naknadama Hrvatske narodne banke*. (NN 94/17), 2017.
 - [249] M. Mimica, M. Tunjić, K. Terlević, Techno-economic analysis of biomass micro-cogeneration facilities in buildings, in 8. *Sabor hrvatskih graditelja, Graditeljstvo i klimatske promjene - Zbornik radova*, 2021, pp. 77–86.
 - [250] TIBCO Software Inc., *TIBCO Statistica Quick Reference*. TIBCO Software Inc., 2018.
 - [251] P. Dalgaard, *Introductory Statistics with R*. New York, USA: Springer, 2008.
 - [252] R. Schumacker, S. Tomek, *Understanding Statistics Using R*. New York: Springer, 2013.
 - [253] A. Radović, *Upoznavanje sa sintaksom jezika R i njegova primjena u osnovnoj statističkoj i grafičkoj analizi podataka*. Zagreb: Sveučilište u Zagrebu, Sveučilišni računski centar, 2015.
 - [254] W. N. Venables, D. M. Smith, and the Core Team, *An Introduction to R, Notes on R: A Programming Environment for Data Analysis and Graphics*, Version 4. 2021.
 - [255] A. H. Taha, *Operations Research: An Introduction*, Seventh Edition. Pearson Education International, 2003.
 - [256] V. Čerić, *Simulacijsko modeliranje*. Zagreb: Školska knjiga, 1993.
 - [257] V. Novaković, *Kvantitativni metodi u građevinskom menadžmentu*. Beograd: Časopis Izgradnja Saveza građevinskih inženjera i tehničara Srbije, Saveza arhitekata Srbije, Društva za mehaniku tla i fundiranje Srbije, Udruženja urbanista Srbije, 2002.
 - [258] H. Schichl, Models and the History of Modeling, 2004, pp. 25–36.
 - [259] W. E. Hart, C. D. Laird, J.-P. Watson *et al.*, *Pyomo — Optimization Modeling in Python*, Second edition, vol. 67. Cham: Springer International Publishing, 2017.
 - [260] M. Čupić, V. M. Rao Tummala, M. Suknović, *Odlučivanje: Formalni pristup*, 4. prerađeno izdanje. Beograd: Fakultet organizacionih nauka, 2001.
 - [261] P. Newbold, J. W. Carlson, M. B. Thorne, *Statistika za poslovanje i ekonomiju*, Šesto izdanje, Zagreb: MATE d.o.o. Zagreb, 2010.
 - [262] D. Barković, *Operacijska istraživanja*, Drugo izdanje, Osijek: Sveučilište J. J. Strossmayera u Osijeku, Ekonomski fakultet, 2001.
 - [263] Y. H. Chan, Biostatistics 201: Linear Regression Analysis, *Singapore Medical Journal*, vol. 45, no. 2, pp. 55–61, 2004.
 - [264] A. F. Graybill, K. H. Iyer, *Regression Analysis: Concepts and Applications*. Duxbury
-

- Pr, 1994.
- [265] G. M. Fitzmaurice, Regression, *Diagnostic Histopathology*, vol. 22, no. 7, pp. 271–278, 2016.
- [266] F. A. Siegel, *Practical Business Statistics*. Burr Ridge, Boston, Sydney: IRWIN, 1994.
- [267] V. Serdar, *Udžbenik statistike*. Zagreb: Školska knjiga, 1966.
- [268] V. Kolesarić, B. Petz, *Statistički rječnik*, II. izdanje. Jastrebarsko: Naklada Slap, 2003.
- [269] B. Petz, *Osnovne statističke metode za nematematičare*, Peto izdanje. Zagreb: Naklada Slap, 2004.
- [270] J. Ažman, V. Frković, L. Bilić-Zulle, M. Petrovečki, Korelacija i regresija, *Acta medica Croatica*, vol. 60, no. 1, pp. 81-91, 2006.
- [271] J. Horvat, J. Mijoč, *Osnove statistike*, Drugo dopunjeno izdanje. Zagreb: Naklada Ljevak, 2014.
- [272] J. S. Prohaska, *Hidrologija II deo - hidrološko prognoziranje, modelovanje i praktična primjena*. Beograd: Institut za vodoprivredu Jaroslav Černi, Rudarsko-geološki fakultet, Beograd, Republički hidrometeorološki zavod, Beograd, 2006.
- [273] B. S. Green, J. N. Salkind, *SPSS za Windows i Macintosh*, Beograd: CET Computer Equipment and Trade, Računarski fakultet Beograd, 2014.
- [274] N. Marić, *Statistika - kompjuterski pristup*. Beograd: DATA STATUS, Beograd, 2009.
- [275] H. Hrelja, *Vjerovatnoća i statistika u hidrologiji*. Sarajevo, Bosna i Hercegovina: Građevinski fakultet Univerziteta u Sarajevu, 2000.
- [276] B. Pasarić, *Osnove statističkih metoda*. Zadar: Filozofski fakultet u Zadru, 2000.
- [277] G. Poropat, S. Milić, Slučajne pogreške u istraživanjima i važnost veličine uzorka, *Medicina Fluminensis*, vol. 53, no. 4, 2017.
- [278] J. C. Ferreira, C. M. Patino, What does the p value really mean?, *Jornal Brasileiro de Pneumologia*, vol. 41, no. 5, pp. 485–485, 2015.
- [279] StatsDirect, P Values, *Statistica I Help*, 2020. [Online]. Dostupno na: https://www.statsdirect.com/help/Default.htm#basics/p_values.htm. (Pristupljeno 15.07.2021.).
- [280] C. Andrade, The P Value and Statistical Significance: Misunderstandings, Explanations, Challenges, and Alternatives, *Indian Journal of Psychological Medicine*, vol. 41, no. 3, pp. 210–215, 2019.
- [281] D. Navarro, D. Foxcroft, *Learning statistics with jamovi: a tutorial for psychology students and other beginners*. 2019.
- [282] A. R. Barnett, R. M. Ziegler, E. K. Byleen, *Primjenjena matematika za poslovanje, ekonomiju, znanosti o živom svijetu i humanističke znanosti*. Zagreb: MATE d.o.o. Zagreb, 2006.
- [283] R. Galić, *Statistika*. Osijek: Elektrotehnički fakultet, Sveučilište Josipa Jurja Strossmayera u Osijeku, 2004.

- [284] A. M. Bello, V. Loftness, *Addressing Inadequate Investment in School Facility Maintenance*, 2010.
- [285] W. W. Hines, C. D. Montgomery, *Probability and Statistics in Engineering and Management Science*. New York, USA: John Wiley & Sons, 1990.
- [286] M. M. Rodríguez del Águila, N. Benítez-Parejo, Simple linear and multivariate regression models, *Allergologia et Immunopathologia*, vol. 39, no. 3, pp. 159–173, 2011.
- [287] G. Grégoire, Multiple Linear Regression, *EAS Publication Series*, vol. 66, pp. 45–72, 2014.
- [288] V. Bahovec, K. Dumičić, N. Erjavec *et al.*, *Statistika*, 2. izdanje. Zagreb: Element, 2016.
- [289] J. Sodikov, Cost estimation of highway projects in developing countries: Artificial neural network approach, *Journal of the Eastern Asia Society for Transportation Studies*, vol. 6, pp. 1036–1047, 2005.
- [290] G. James, D. Witten, T. Hastie, R. Tibshirani, *An Introduction to Statistical learning with Applications in R*. Los Angeles, USA: Springer US, 2013.
- [291] M. Benšić, N. Šuvak, *Primijenjena statistika*. Osijek: Sveučilište J. J. Strossmayera u Osijeku, Odjel za matematiku, 2013.
- [292] M. Merkle, *Verovatnoća i statistika za inženjere i studente tehnike*. Beograd: Akademska misao, 2002.
- [293] J. Unpingco, *Python for Probability, Statistics, and Machine Learning*. Cham: Springer International Publishing, 2019.
- [294] F. B. Enders, Coefficient of determination, *Encyclopedia Britannica*, 2020. [Online]. Dostupno na: <https://www.britannica.com/science/coefficient-of-determination>. (Pristupljeno 24.07.2021.).
- [295] S. Chatterjee, S. A. Hadi, *Sensitivity Analysis in Linear Regression*. New York, USA: John Wiley & Sons, 1988.
- [296] R. E. Chaddock, *Principles and Methods of Statistics*. The Riverside Press, Cambridge, 1925.
- [297] D. Bebić, L. Stazić, A. Mišura, I. Komar, EDD – Economic Benefit Analysis of Extending Dry Docking Interval, *Transactions on Maritime Science*, vol. 7, no. 02, pp. 164–173, 2018.
- [298] J. Perković, 10. regresija i korelacija. Zadar. [Online]. Dostupno na: http://www.unizd.hr/portals/4/nastavni_mat/2_godina/statistika/10_predavanje.pdf (Pristupljeno: 15.08.2021.).
- [299] A. Manikantan, Akaike Information Criterion: Model Selection, *Medium.com*, 2021. [Online]. Dostupno na: <https://medium.com/geekculture/akaike-information-criterion-model-selection-c47df96ee9a8>. (Pristupljeno 24.07.2021.).
- [300] M. Udovičić, K. Baždarić, L. Bilić-Zulle, M. Petrovečki, Što treba znati kada izračunavamo koeficijent korelacije?, *Biochemia Medica*, vol. 17, no. 1, pp. 10–15, 2007.

-
- [301] M. R. Forster, Key Concepts in Model Selection: Performance and Generalizability, *Journal of Mathematical Psychology*, vol. 44, no. 1, pp. 205–231, 2000.
- [302] D. G. Mayer, D. G. Butler, Statistical validation, *Ecological Modelling*, vol. 68, no. 1–2, pp. 21–32, 1993.
- [303] H. Akaike, Factor analysis and AIC, *Psychometrika*, vol. 52, no. 3, pp. 317–332, 1987.
- [304] H. Bozdogan, Model selection and Akaike's Information Criterion (AIC): The general theory and its analytical extensions, *Psychometrika*, vol. 52, no. 3, pp. 345–370, 1987.
- [305] J. E. Cavanaugh, A. A. Neath, The Akaike information criterion: Background, derivation, properties, application, interpretation, and refinements, *WIREs Computational Statistics*, vol. 11, no. 3, pp. 1–11, 2019.
- [306] E. J. Wagenmakers, S. Farrell, AIC model selection using Akaike weights, *Psychonomic Bulletin & Review*, vol. 11, no. 1, pp. 192–196, 2004.
- [307] Alphabetical glossary of useful statistical and research related terms, 2022. [Online]. Dostupno na: <https://onlinepubs.trb.org/onlinepubs/nchrp/cd-22/glossary.html#152>. (Pristupljeno 24.08.2021.).
- [308] J. K. Kruschke, Metric Predicted Variable with Multiple Metric Predictors, in *Doing Bayesian Data Analysis*, Elsevier, 2015, pp. 509–551.
- [309] B. Obi Tayo, Simplicity vs Complexity in Machine Learning — Finding the Right Balance, 2019. [Online]. Dostupno na: <https://towardsdatascience.com/simplicity-vs-complexity-in-machine-learning-finding-the-right-balance-c9000d1726fb>. (Pristupljeno 24.08.2021.).
- [310] V. Žiljak, *Simulacija računalom*. Zagreb: Školska knjiga, 1982.
- [311] N. Tsiptsias, A. Tako, S. Robinson, Model validation and testing in simulation: a literature review, in *5th Student Conference on Operational Research*, 2016, pp. 1–11.
- [312] J. M. McKinion, D. N. Baker, Modeling, Experimentation, Verification and Validation: Closing the Feedback Loop, *Transactions of the ASAE*, vol. 25, no. 3, pp. 0647–0653, 1982.
- [313] J. Guszczka, The Basics of Model Validation, *CAS Predictive Modeling Seminar*, 2005. [Online]. Dostupno na: <https://slideplayer.com/slide/6204185/>. (Pristupljeno 24.08.2021.).
- [314] G. Dunn, M. Mirandola, F. Amaddeo, M. Tansella, Describing, explaining or predicting mental health care costs: a guide to regression models, *British Journal of Psychiatry*, vol. 183, no. 5, pp. 398–404, 2003.
- [315] R. Mathisen, On-line NIR analysis in a high density polyethene plant, evaluation of sampling system and optimal calibration strategy, Telemark College, Porsgrunn, Norway, 1999.
- [316] IBM Cloud Education, Overfitting, *IBM Cloud Learn Hub*, 2021. [Online]. Dostupno na: <https://www.ibm.com/cloud/learn/overfitting#toc-how-to-det-Aqv1nwvv>. (Pristupljeno 27.08.2021.).
- [317] C. Willmott, K. Matsuura, Advantages of the mean absolute error (MAE) over the root
-

- mean square error (RMSE) in assessing average model performance, *Climate Research*, vol. 30, pp. 79–82, 2005.
- [318] T. Chai, R. R. Draxler, Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature, *Geoscientific Model Development*, vol. 7, no. 3, pp. 1247–1250, 2014.
- [319] M. Kovačević, N. Ivanišević, T. Dašić, L. Marković, Application of artificial neural networks for hydrological modelling in Karst, *Građevinar*, vol. 70, no. 1, pp. 1–10, 2018.
- [320] L. Tang-Huang, C. V. Le, L. T., Pham *et al.*, Retrieval of Aerosol Optical Depth Using Satellite Data Associated with Ground-based Observations over Urban and Rural Areas, *Kartografija i geoinformacije*, vol. 18, no. 32, pp. 4–17, 2019.
- [321] J. O'Brien, G. Marakas, *Management Information Systems*, 10th edition. New York: McGraw-Hill, Irwin, 2011.
- [322] A. Puška, Analiza osjetljivosti u funkciji investicijskog odlučivanja, *Praktični menadžment: stručni časopis za teoriju i praksu menadžmenta*, vol. 2, no. 3, pp. 80–86, 2011.
- [323] Directorate-General for Regional and Urban policy, European Union, European Commission, *Vodič kroz analizu troškova i koristi investicijskih projekata*. Brussels, Belgium: European Commission, 2014.
- [324] B. Iooss, A. Saltelli, Introduction to Sensitivity Analysis, in *Handbook of Uncertainty Quantification*, Cham: Springer International Publishing, 2015, pp. 1103–1122.
- [325] S. Marenjak, H. Krstić, *Održavanje zgrada javne namjene*. Osijek: Građevinski i arhitektonski fakultet Osijek, 2020.
- [326] E. Castillo, A. S. Hadi, A. Conejo, A. Fernández-Canteli, A General Method for Local Sensitivity Analysis With Application to Regression Models and Other Optimization Problems, *Technometrics*, vol. 46, no. 4, pp. 430–444, Nov. 2004.
- [327] A. Saltelli, S. Tarantola, F. Campolongo, Sensitivity Analysis as an Ingredient of Modeling, *Statistical Science*, vol. 15, no. 4, pp. 377–395, 2000.
- [328] A. Saltelli, Sensitivity Analysis for Importance Assessment, *Risk Analysis*, vol. 22, no. 3, pp. 579–590, 2002.
- [329] C. Pichery, Sensitivity Analysis, in *Encyclopedia of Toxicology*, Elsevier, 2014, pp. 236–237.
- [330] R. Kartelo, Analiza rizika u ekonomskoj ocjeni projekta na primjeru vodoopskrbnog sustava Zagreba, *Građevinar*, vol. 58, no. 11, pp. 889–898, 2006.
- [331] M. Karić, *Analiza rizika*. Osijek: Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku, 2006.
- [332] T. L. Blank, J. A. Tarquin, *Engineering economy*, Fourth edition. New York, USA: WCB, McGraw-Hill, 1998.

PRILOG 1 – Zamolba za dostavu podataka i anketni upitnik za poduzeća koja upravljaju kanalizacijskim sustavima

Dino Obradović

Građevinski i arhitektonski fakultet Osijek

Vladimira Preloga 3, 31000 Osijek

Predmet: Zamolba za dostavu podataka

Poštovana/i,

Radim na Građevinskom i arhitektonskom fakultetu Osijek. U svrhu istraživanja za temu doktorske disertacije i samu izradu doktorske disertacije potrebni su mi razni podatci o kanalizacijskom sustavu (molim vidjeti prilog).

Okvirna tema doktorske disertacije bi bila optimizacija održavanja kanalizacijskog sustava, a svrha je izraditi (novu) metodologiju i način održavanja koji bi bio troškovno efikasniji, predviđao moguće kvarove na kanalizacijskom sustavu te bi se istražili i ostali aspekti održavanja kanalizacijskog sustava.

U svrhu izrade istraživanja molio bih Vas ako možete ispuniti upitnik koji se nalazi u privitku (prilog u Excel dokumentu s 5 kartica). Veoma bih cijenio da odvojite vrijeme za ispunjavanje ovog upitnika.

Svi podatci navedeni u upitniku neće biti pojedinačno dani u rezultatima istraživanja, povjerljivi su i svaki će upitnik biti pod šifrom (tj. svako poduzeće zaduženo za odvodnju – neće se navoditi imena).

Ako nemate sve tražene podatke, onda Vas molim da ispunite one koje imate (a neke ako je moguće iskustveno pretpostavite). Podatke bih Vas molio da dostavite tijekom jednog mjeseca, ili čim prije budete mogli (zbog nadolazećih godišnjih odmora). Ako je potrebno ispuniti i potpisati izjavu o povjerljivom postupanju s ustupljenim podacima, molimo javite.

Još jednom se nadam da ćete mi izaći ususret i ispuniti upitnik traženim podacima. Stojim na raspolaganju za sve upite putem e-mail adrese: dobradovic@gfos.hr

Unaprijed hvala.

S poštovanjem,

Dino Obradović, mag. ing. aedif.

U Osijeku, 23. 07. 2019.

1. OPĆI PODATCI O PODUZEĆU, OPREMI I ODRŽAVANJU			
R. Br.	Traženi podatak	Ovdje upisivati odgovor	Napomena
1.	Naziv poduzeća		
2.	Adresa		
3.	Broj zaposlenih na poslovima održavanja kanalizacijskog sustava		
4.	Ukupan broj zaposlenih u poduzeću		
5.	Područje (navesti naselja) na kojem se obavlja djelatnost odvodnje		
6.	Broj specijalnih vozila za održavanje kanal. sustava [kom], od toga:		
7.	a) bager – kombinirka		
8.	b) specijalna vozila za čišćenje kanalizacije (npr. Canalmaster, Muller ...)		
9.	c) ostalo (navesti što i broj)		
10.	Posjeduje li poduzeće opremu za CCTV snimanje?		
11.	Je li kanal. sustav prikazan u GIS-u?		
12.	Znate li što su to ekspertni sustavi? (DA/NE)		
13.	Koristite li ekspertni sustav kao pomoć kod održavanja?		
14.	Ako koristite, navedite koji.		
15.	Temelji li se održavanje kanal. sustava samo na popravljaju kvarova i nedostataka?		
16.	Postoji li preventivna strategija održavanja kanal. sustava za određeno razdoblje?		
17.	Ako postoji, za koje je to vremensko razdoblje?		
18.	Mislite li da je isplativije preventivno održavanje ili reaktivno i ukratko objasnite zašto.		
	*		
	*Slobodno dodati red(ove) ukoliko neki podatak nije obuhvaćen u tablici, a vezan je za tražene podatke ili neophodan.		

2. OPĆI PODATCI O KANALIZACIJSKOM SUSTAVU			
R. Br.	Traženi podatak	Ovdje upisivati odgovor	Napomena
1.	Vrsta kanalizacije i pripadajuće duljine pojedinog dijela [km], od toga:		
2.	a) mješovita		
3.	b) tlačna		
4.	c) gravitacijska		
5.	d) razdjelna		
6.	e) oborinska		
7.	f) vakuumska		
8.	g) fekalna		
9.	h) ostalo (navesti što)		
10.	Ukupna duljina kanalizacijskog sustava [km]		
11.	Ukupan broj priključaka na kanalizaciju [kom], od toga:		
12.	a) kućanstva		
13.	b) tvornice		
14.	c) trgovine, kafići		
15.	d) ostalo (navesti što)		
16.	Broj crpnih stanica [kom]		
17.	Pročišćavaju li se otpadne vode, ili se samo ispuštaju u recipijent?		
18.	Broj uređaja za pročišćavanje otpadnih voda [kom]		
19.	Priključenost stanovništva na kanalizacijski sustav [%]		
20.	Starost kanal. sustava [god]		
	*		
	*Slobodno dodati red(ove) ukoliko neki podatak nije obuhvaćen u tablici, a vezan je za tražene podatke ili neophodan.		

3. KOLIČINE ODVOĐENJA (ISPUŠTANJA) OTPADNIH VODA			
R. Br.	Traženi podatak	Ovdje upisivati odgovor	Napomena
1.	Količina odvođenja otpadnih voda [m3] za pojedinu godinu:		
2.	2018		
3.	2017		
4.	2016		
5.	2015		
6.	2014		
7.	2013		
8.	2012		
9.	2011		
10.	2010		
11.	2009		
	*		
	*Slobodno dodati red(ove) ukoliko neki podatak nije obuhvaćen u tablici, a vezan je za tražene podatke ili neophodan.		

4. PODATCI O PROMJERIMA, VRSTAMA I DULJINAMA CIJEVI				
R. Br.	Traženi podatak	Ovdje upisivati odgovor		Napomena
1.	Vrste korištenih cijevi, od toga:	Duljina [km]	Promjer [mm]	
2.	a) beton			
3.	b) salonit			
4.	c) polipropilen			
5.	d) zidani kanal			
6.	e) UKC PVC			
7.	f) GRP			
8.	g) ostalo (navesti što)			
9.	Dubine [m] postavljanja cijevi, od toga:	Duljina [km]	Dubina [m]	
10.	a) beton			
11.	b) salonit			
12.	c) polipropilen			
13.	d) zidani kanal			
14.	e) UKC PVC			
15.	f) GRP			
16.	g) ostalo (navesti što)			
17.	Duljine [km] korištenih cijevi, od toga:			
18.	a) beton			
19.	b) salonit			
20.	c) polipropilen			
21.	d) zidani kanal			
22.	e) UKC PVC			
23.	f) GRP			
24.	g) ostalo (navesti što)			
	*			
*Slobodno dodati red(ove) ukoliko neki podatak nije obuhvaćen u tablici, a vezan je za tražene podatke ili neophodan.				

5. PODATCI O ODRŽAVANJU KANALIZACIJSKOG SUSTAVA												
R. Br.	Traženi podatak	2018.	2017.	2016.	2015.	2014.	2013.	2012.	2011.	2010.	2009.	
		Godine										
1.	Troškovi održavanja sustava za pojedinu godinu [kn], od toga:											
2.	a) strojni rad											
3.	b) ljudski rad											
4.	c) materijal											
5.	d) ostalo (navesti što)											
6.	Broj kvarova u pojedinoj godini **											
7.	Najučestaliji kvarovi (nabrojati): **											
8.	Troškovi rada (el. energije) crpnih stanica [kn]											
9.	Troškovi održavanja crpnih stanica [kn]											
10.	Troškovi CCTV snimanja [kn]											
11.	Koliko km je snimljeno CCTV?											
12.	Troškovi čišćenja (ispiranja) kanal. sustava [kn] ***											
13.	Koliko km je (isprano) očišćeno?											
14.	Troškovi sanacije bez iskopa [kn]											
15.	Koliko km je sanirano bez iskopa?											
16.	Gorivo utrošeno na održavanje [kn] ili [litara]											
*												
	NAPOMENE:											
	* Slobodno dodati red(ove) ukoliko neki podatak nije obuhvaćen u tablici, a vezan je za tražene podatke ili neophodan.											


PRILOG 2 – Deskriptivna statistika baze podataka za razvoj matematičkog modela procjene troškova održavanja


Variable	Descriptive Statistics (DOKMJESTA12)				
	Valid N	Mean	Minimum	Maximum	Std.Dev.
Prosječna sadašnja vrijednost troškova održavanja	12	999633	5711.960	5172114	1565204
Prosječni godišnji nominalni troškovi održavanja	12	815335	5000.000	4190500	1266664
Prosječna godišnja količina otpadnih voda	12	3065013	4197.333	14223945	4377845
Prosječna starost	12	40	5.000	80	23
Broj uređaja za pročišćavanje otpadnih voda	12	3	0.000	7	2
Broj crpnih stanica	12	36	1.000	92	33
Ukupan broj priključaka	12	11020	55.000	30805	9921
Ukupna duljina kanal. sustava	12	222	5.100	752	225
Broj zaposlenih	12	14	2.000	32	11


PRILOG 3 – Korelacije zavisne i neovisnih varijabli


Correlations (DOKMJESTA12) Marked correlations are significant at $p < .05000$ N=12 (Casewise deletion of missing data)									
Variable	Broj zaposlenih	Ukupna duljina kanal. sustava	Ukupan broj priključaka	Broj općih stanica	Broj uređaja za pročišćavanje otpadnih voda	Prosječna starost	Prosječna godišnja količina otpadnih voda	Prosječni godišnji nominalni troškovi održavanja	Prosječna sadašnja vrijednost troškova održavanja
Prosječni godišnji nominalni troškovi održavanja	0.52491 [*]	0.91005 [*]	0.77359 [*]	0.58417 [*]	0.29640 [*]	0.45512 [*]	0.79222 [*]	1.00000 [*]	0.99993 [*]
Prosječna starost	0.32670 [*]	0.47434 [*]	0.46232 [*]	0.37552 [*]	0.52150 [*]	1.00000 [*]	0.23547 [*]	0.45612 [*]	0.45068 [*]
Broj zaposlenih	1.00000 [*]	0.69388 [*]	0.87780 [*]	0.48575 [*]	0.45197 [*]	0.32670 [*]	0.66597 [*]	0.52491 [*]	0.51968 [*]
Ukupna duljina kanal. sustava	0.69388 [*]	1.00000 [*]	0.92215 [*]	0.78242 [*]	0.52578 [*]	0.47434 [*]	0.86687 [*]	0.91005 [*]	0.90812 [*]
Ukupan broj priključaka	0.87780 [*]	0.92215 [*]	1.00000 [*]	0.69303 [*]	0.44814 [*]	0.46232 [*]	0.88344 [*]	0.77359 [*]	0.77120 [*]
Broj općih stanica	0.48575 [*]	0.78242 [*]	0.69303 [*]	1.00000 [*]	0.76310 [*]	0.37552 [*]	0.47241 [*]	0.58417 [*]	0.58186 [*]
Broj uređaja za pročišćavanje otpadnih voda	0.45197 [*]	0.52578 [*]	0.44814 [*]	0.76310 [*]	1.00000 [*]	0.52150 [*]	0.12124 [*]	0.29640 [*]	0.28807 [*]
Prosječna godišnja količina otpadnih voda	0.66597 [*]	0.86687 [*]	0.88344 [*]	0.47241 [*]	0.12124 [*]	0.23547 [*]	1.00000 [*]	0.79222 [*]	0.79287 [*]
Prosječna sadašnja vrijednost troškova održavanja	0.51968 [*]	0.90812 [*]	0.77120 [*]	0.58186 [*]	0.28807 [*]	0.45068 [*]	0.79287 [*]	0.99993 [*]	1.00000 [*]


Variable	Correlations (DOKMJESTA12) Marked correlations are significant at $p < .05000$ N=12 (Casewise deletion of missing data)	
	Prosječni godišnji nominalni troškovi održavanja	
Prosječna sadašnja vrijednost troškova održavanja	0.999937	
Prosječni godišnji nominalni troškovi održavanja	1.000000	
Prosječna godišnja količina otpadnih voda	0.792220	
Prosječna starost	0.455129	
Broj uređaja za pročišćavanje otpadnih voda	0.296405	
Broj crpnih stanica	0.584172	
Ukupan broj priključaka	0.773591	
Ukupna duljina kanal. sustava	0.910055	
Broj zaposlenih	0.524912	


























PRILOG 4 – Dijagrami raspršenosti za model s interakcijama







PRILOG 5 – Prijedlog obrasca za ujednačeno prikupljanje podataka o održavanju kanalizacijskog sustava

Obrazac za prikupljanje podataka o održavanju kanalizacijskog sustava

Traženi podatak	Odgovor	Napomena
Naziv poduzeća		
Adresa		
Pretežita vrsta kanalizacije (mješovita, oborinska, fekalna)		
Godina na koju se odnose podatci		
Ukupna duljina kanalizacijske mreže [km]		
Broj priključaka na kanal. sustav [kom]		
Broj crpnih stanica		
Broj UPOV-a		
Priključenost stanovništva na kanal. sustav [%]		
Starost kanal. sustava [god]		
Količina otpadnih voda [m ³]		
Troškovi održavanja kanal. sustava [HRK]		

Odgovorna osoba u pravnoj osobi koja je ispunila obrazac:

Mjesto i datum:

CURRICULUM VITAE

Dino Obradović rođen je 13. ožujka 1989. godine u Osijeku, Republika Hrvatska. Osnovnu školu završio je u Donjem Miholjcu 2004. godine. U Donjem Miholjcu pohađao je Srednju školu Donji Miholjac, program opće gimnazije koju završava 2008. godine. Iste godine upisuje sveučilišni preddiplomski studij na Građevinskom fakultetu Osijek, Sveučilišta Josipa Jurja Strossmayera u Osijeku gdje diplomira u lipnju 2013. godine te stječe zvanje magistar inženjer građevinarstva.

Tijekom 2013. godine završio je program pedagoško-psihološko-didaktičko-metodičke izobrazbe na Filozofskom fakultetu Osijek. Od prosinca 2013. do prosinca 2016. godine radio je kao viši stručni suradnik za prostorno uređenje i graditeljstvo u Upravnom odjelu za prostorno uređenje i graditeljstvo Osječko-baranjske županije. Godine 2014. položio je državni stručni ispit za višeg stručnog suradnika u Ministarstvu uprave u Zagrebu. Akademske godine 2015./2016. upisuje poslijediplomski sveučilišni studij Građevinarstvo na Građevinskom i arhitektonskom fakultetu Osijek.

Od ožujka do prosinca 2017. godine radio je na Građevinskom fakultetu Osijek u naslovnom suradničkom zvanju asistenta. Godine 2017. položio je stručni ispit za obavljanje poslova prostornog uređenja i graditeljstva pri Ministarstvu graditeljstva i prostornoga uređenja u Zagrebu. Dana 8. siječnja 2018. godine počinje raditi kao asistent na Građevinskom i arhitektonskom fakultetu Osijek, Zavodu za organizaciju, tehnologiju i menadžment gdje radi i danas. Drži vježbe na sveučilišnom preddiplomskom studiju Građevinarstvo iz kolegija Organizacija građenja I, sveučilišnom preddiplomskom studiju Arhitektura i urbanizam iz kolegija Organizacija građenja te na sveučilišnom diplomskom studiju Građevinarstvo, smjer Organizacija, tehnologija i menadžment građenja iz kolegija Održavanje objekata, Upravljanje projektima i Procesi planiranja i kontrole građenja.

Član je Hrvatske udruge za organizaciju građenja, Društva građevinskih inženjera Osijek, Hrvatskog društva održavatelja, Hrvatskog hidrološkog društva i Hrvatskog društva za operacijska istraživanja.

