DIJAGNOZA KVARA U DISTRIBUTIVNOJ MREŢI POMOĆU SUSTAVA S NEIZRAZITOM LOGIKOM

Kaluđer, Slaven

Doctoral thesis / Disertacija

2014

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:904233

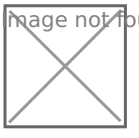
Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek





SVEUČILIŠTE JOSIPA JURIJA STROSSMAYERA U OSIJEKU

ELEKTROTEHNIČKI FAKULTET OSIJEK

SLAVEN KALUĐER

DIJAGNOZA KVARA U DISTRIBUTIVNOJ MREŽI POMOĆU SUSTAVA S NEIZRAZITOM LOGIKOM

Doktorski rad

Osijek, 2014.

Doktorska disertacija je izrađena na Elektrotehničkom fakultetu Osijek Josipa Jurija Strossmayera u Osijeku

Mentor: prof. dr. sc. Lajos Jozsa

Doktorski rad ima: 160 stranica

Doktorski rad broj: 47

POVJERENSTVO ZA OCJENU DOKTORSKE DISERTACIJE:

1. dr.sc. Srete Nikolovski, redoviti profesor, predsjednik, Elektrotehnički fakultet Osijek
2. dr.sc. Lajos Jozsa, redoviti profesor, mentor, Elektrotehnički fakultet Osijek
3. dr.sc. Ivica Pavić, redoviti profesor, član, Fakultet elektrotehnike i računarstva u Zagrebu

POVJERENSTVO ZA OBRANU DOKTORSKE DISERTACIJE:

1. dr.sc. Srete Nikolovski, redoviti profesor, predsjednik, Elektrotehnički fakultet Osijek
2. dr.sc. Lajos Jozsa, redoviti profesor, mentor, Elektrotehnički fakultet Osijek
3. dr.sc. Ivica Pavić, redoviti profesor, član, Fakultet elektrotehnike i računarstva u Zagrebu
4. dr.sc. Marinko Barukčić, docent, član, Elektrotehnički fakultet Osijek
5. dr.sc. Predrag Marić, docent, član, Elektrotehnički fakultet Osijek

Datum obrane: 18. studenog 2014.

SADRŽAJ:

1. UVOD……..8

1.1. Temeljni cilj i plan istraživanja u disertacije……...10

1.2. Znanstveni doprinosi istraživanja……..……..11

1.3. Organizacija i struktura doktorske disertacije…….11

2. PREGLED LITERATURE…….13

2.1. Ekspertni sustavi za dijagnozu kvara (off-line)……...13

2.1.1. Ekspertni sustavi na bazi pravila ……..13

2.1.2. Ekspertni sustavi na bazi modela……...……...15

2.1.3. Neizraziti ekspertni sustavi……...……..……..15

2.2. Ekspertni sustavi za dijagnoszu kvara (on-line)…..……..……..16

2.2.1. Ekspertni sustavi na bazi pravila ……..16

2.2.2. Ekspertni sustavi na bazi modela ……...…17

2.2.3. Neizraziti ekspertni sustavi……17

2.3. Druga područja primjene i druge metode…….....18

3. DIJAGNOZA KVARA……21

3.1. Razlozi za dijagnozu kvara u elektroenergetskom sustavu…….....21

3.2. Struktura dijagnoze kvara u elektroenergetskom sustavu……23

3.3. Metode za dijagnozu kvara u elektroenergetskom sustavu…….……25

3.3.1. Optimizacijske metode za dijagnozu kvara……..27

3.3.2. Hibridne metode za dijagnozu kvara……28

3.4. Nesigurnost prilikom dijagnoze kvara…….29

4. EKSPERTNI SUSTAVI……..30

4.1.Uvod……....30

4.2. Struktura ekspertnog sustava…….....30

4.3. Prikazivanje baze znanja……..33

4.4. Tehnike zaključivanja kod ekspertnih sustava…….....34

5. NEIZRAZITA LOGIKA…….36

5.1. Alternativni operatori…….....36

5.1.1. T-norme…….36

5.1.2. T-conorme…….37

5.2. Neizraziti ekspertni sustavi…….38

5.2.1. Sugeno model neizrazitog ekspertnog sustava……...……...38

5.2.2. Mamdani model neizrazitog ekspertnog sustava……...……39

5.3. Modeliranje nepostojećih informacija pomoću neizrazite logike……40

5.4. Identifikacija kvara pomoću neizrazite logike…….43

5.4.1. Identifikacija kvara pomoću alternativnih operatora.……44

6. METODOLOGIJA……..45

6.1. Releji……...45

6.1.1. Ispravna funkcionalna stanja releja i pripadajućeg prekidača prikazano pomoću klasičnog i neizrazitog skupa……49

6.1.2. Funkcionalno djelovanje releja……..53

6.1.3. Model distributivne mreže…….55

6.2. Dalekovod 10 kV……56

6.2.1. Ispravno djelovanje nadstrujnog releja koji štiti dalekovod 10 kV……...56

6.2.2. Krivo djelovanje nadstrujnog releja koji štiti dalekovod 10 kV ……...57

6.2.3. Otkazivanje djelovanja nadstrujnog releja koji štiti dalekovod 10 kV …….58

6.2.4. Ispravno djelovanje kratkospojnog releja koji štiti dalekovod 10 kV ……..60

6.2.5. Krivo djelovanje kratkospojnog releja koji štiti dalekovod 10 kV ……...60

6.2.6. Otkazivanje djelovanja kratkospojnog releja koji štiti dalekovod 10 kV.....61

6.2.7. Ispravno djelovanje zemljospojnog releja koji štiti dalekovod 10 kV …….63

6.2.8. Krivo djelovanje zemljospojnog releja koji štiti dalekovod 10 kV ……..63

6.2.9. Otkazivanje djelovanja zemljospojnog releja koji štiti dalekovod 10 kV…….64

6.3. Transformator……66

6.3.1. Ispravno djelovanje nadstrujnog releja koji štiti transformator…….....66

6.3.2. Krivo djelovanje nadstrujnog releja koji štiti transformator……66

6.3.3. Otkazivanje djelovanja nadstrujnog releja koji štiti transformator……...68

6.4. Dalekovod 35 kV……69

6.4.1. Ispravno djelovanje kratkospojnog releja koji štiti dalekovod 35 kV……...69

6.4.2. Krivo djelovanje kratkospojnog releja koji štiti dalekovod 35 kV …….....70

6.4.3. Otkazivanje djelovanja kratkospojnog releja koji štiti dalekovod 35 kV 71

6.4.4. Ispravno djelovanje nadstrujnog releja koji štiti dalekovod 35 kV ……..72

6.4.5. Krivo djelovanje nadstrujnog releja koji štiti dalekovod 35 kV ……...73

6.4.6. Otkazivanje djelovanja nadstrujnog releja koji štiti dalekovod 35 kV……..74

6.4.7. Ispravno djelovanje zemljospojnog releja koji štiti dalekovod 35 kV ….....75

6.4.8. Krivo djelovanje zemljospojnog releja koji štiti dalekovod 35 kV ……..76

6.4.9. Otkazivanje djelovanja zemljospojnog releja koji štiti dalekovod 35 kV…….77

6.5. Prekidači……78

6.6. Dalekovod 10 kV……80

6.6.1. Ispravano djelovanje prekidača na dalekovodu 10 kV……...……...80

6.6.2. Krivo djelovanje prekidača na dalekovodu 10 kV..…….81

6.6.3. Otkazivanje djelovanja prekidača na dalekovodu 10 kV……..…82

6.7. Transformatorsko polje……83

6.7.1. Ispravano djelovanje oba prekidača na transformatorskom polju…….……83

6.7.2. Krivo djelovanje oba prekidača na transformatorskom polju ……..84

6.7.3. Otkazivanje djelovanja oba prekidača na transformatorskom polju …...…….85

6.8. Dalekovod 35 kV……86

6.8.1. Ispravano djelovanje prekidača na dalekovodu 35 kV……...……...86

6.8.2. Krivo djelovanje prekidača na dalekovodu 35 kV……...…….87

6.8.3. Otkazivanje djelovanja prekidača na dalekovod 35 kV……..……..88

6.9. Identifikacija kvara……...89

6.10. Jednostruki kvarovi……89

6.10.1. Identifikacija kvara na dalekovodnom polju 10 kV (nadstrujna zaštita)…....89

6.10.2. Identifikacija kvara na dalekovodnom polju 10 kV (kratkospojna zaštita).....90

6.10.3. Identifikacija kvara transformatorskom polje……...91

6.10.4. Identifikacija kvara dalekovodnom polju 35 kV…….……..92

6.11. Dvostruki kvarovi……93

6.11.1. Dvostruki kvar na dalekovodu 10 kV i dalekovodu 35 kV…..……..93

6.11.2. Dvostruki kvar na dalekovodu 10 kV i transformatoru…….94

6.11.3. Dvostruki kvar na transformatoru i dalekovodu 35 kV…….95

6.12. Sagitalni dijagrami……...……...96

7. REZULTATI……...……...103

7.1. Slučaj I……...……103

7.1.1. Dijagnoza I……103

7.2. Slučaj II……..104

7.2.1. Dijagnoza II……..105

7.3. Slučaj III……...……..106

7.3.1. Dijagnoza III…….107

7.4. Slučaj IV……...……..108

7.4.1. Dijagnoza IV……..109

7.5. Slučaj V……..110

7.5.1. Dijagnoza V…….110

7.6. Slučaj VI……...……..111

7.6.1. Dijagnoza VI……..112

7.7. Slučaj VII……...……..113

7.7.1. Dijagnoza VII……..113

7.8. Slučaj VIII……..115

7.8.1. Dijagnoza VIII…….117

8. ZAKLJUČAK…….119

9. LITERATURA……...122

DODATAK ……..……..……134

Dodatak A:…….134

Dodatak B:…….142

Dodatak C:…….146

Dodatak D:…….150

POPIS SLIKA……..……...152

POPIS TABLICA…….……..…157

SAŽETAK…….…158

SUMMARY…….……..……..159

ŽIVOTOPIS……..……..160

1. UVOD

Elektroenergetski sustavi (EES) diljem svijeta postaju sve veći i složeniji, a njihov je rad na granicama mogućnosti. Neprekinuta isporuka električne energije važan je čimbenik koji utječe na niz događaja i odnosa u samom društvu. Česti raspadi EES-a doveli su do značajnih šteta financijske prirode zbog neisporučene električne energije dok se ne uspostavi normalno stanje i tužbe kupaca električne energije za nastalu štetu zbog ne isporuke električne energije. Raspad EES-a 1977. godine u New Yorku bio je povod masovnim pljačkama, razbojstvima, neredima te izazvao ogromnu financijsku štetu [83]. Također situacija na Otoku tri milje 1979. godine prouzročila je veliku ekološku katastrofu. Nakon tih događaja koji imaju zajednički uzrok (nesnalaženje operatera za vrijeme kriznih situacija) nešto je trebalo poduzeti kako bi se takve situacije smanjile na najmanju moguću mjeru. Te su katastrofe iznjedrile ideju o automatiziranju i sustavnijoj obradi informacija na bazi kojih operateri donose odluke. Priroda problema te vrste je dijagnostička, a opći izraz je dijagnoza kvara [41, 53, 77, 98, 121] što podrazumijeva pronalazak: kvarova releja, kvarova prekidača, kvarova telemetrije i identifikaciju kvara. Kvar u EES–u aktivira sustav relejne zaštite koji izolira dionicu u kvaru. Aktivacija određene zaštite šalje signal (alarm) [42, 43, 134] lokalno u trafostanicu (TS) i daljinski u dispečerski centar. U dispečerskom centru alarmi su vidljivi preko sustava SCADA koji uz koji uz mogućnost daljinskog upravljanja, mjerenja i nadzora sadrži kronološki registrator događaja (KRD). Alarmi koji dolaze u dispečerski centar pojavljuju se na KRD–u i tamo ostaju pohranjeni. Alarmi koji dolaze iz postrojenja odnose se na primarni i sekundarni dio postrojenja. Široka skupina alarma obuhvaća: signalizaciju položaja prekidača i rastavljača tj. njihovo sklopno stanje, aktivaciju i isključenje određene zaštite, ispade pojedinih automatskih sklopki u sekundarnom razvodu, ispade pojedinih uređaja u sekundarnom razvodu i do nekih skoro nevažnih alarma kao što je signalizacija otvorenih vrata TS i drugi. Svi ti alarmi naviru u trenutku kvara na zaslon KRD–a i slažu se jedan na drugi tako da alarm na samom vrhu predstavlja vremenski zadnju situaciju koja se dogodila u mreži. Sve je u redu dok je broj alarma i situacija u mreži jednostavna. Pojavom nekoliko stotina alarma u kratkom vremenskom periodu situacija se komplicira i vrlo je teško pronaći dionicu i uzrok kvara što onemogućava reakciju samog operatera kako bi uspostavio početno uklopno stanje u mreži, te ga može navesti na pogrešku. Zbog takvih situacija pribjegavamo primjeni metodama za analiziranje alarma. Postoje dvije standardne metode koje koristi čovjek prilikom analiziranja alarma, a to su [71]: metoda niza i metoda hipoteza. Metoda niza se primjenjuje kada imamo mali broj alarma i situaciju za koju možemo

egzaktno reći koja je dionica u kvaru i što je uzrok toga kvara. Metodu niza koristimo kada poznajemo činjenice, informacije i logički idemo prema cilju. Metoda hipoteza se primjenjuje u situacijama većeg broja alarma, u situacijama gdje ne možemo sa 100% sigurnošću reći koja je dionica u kvaru i što je uzrok kvara. Metodu hipoteza koristi se za drugu vrstu problema kada nam činjenice i informacije nisu poznate pa krećemo od hipoteza. Kako bi se pomoglo operaterima u odlučivanju i postavljanju dijagnoze razvijaju se automatizirani sustavi za dijagnozu kvara i pomoć pri odlučivanju. Prvenstveno se razvijaju off-line sustavi (faza 1) za dijagnozu kvara koji služe za [28, 62, 65]:

- dijagnozu kvara prilikom zastoja računalnog sustava za nadzor i upravljanje,
- trening operatera,
- potvrdu koncepta i
- istraživanje.

Razvoj on-line sustava (faza 2) za dijagnozu kvara koji se nazivaju i procesorima alarma razvijaju se iz off-line sustava (faza 1) [28, 65, 77]. Umjetna inteligencija (UI) se pokazala izrazito uspješna u rješavanju problema dijagnoze u odnosu na tradicionalne numeričke metode (ne postoji zadovoljavajući numerički algoritam) [39, 43, 49, 99, 117]. Odabir metode (UI) za rješavanje problema dijagnoze kvara prvenstveno ovisi o ulaznim (dostupnim) podacima, a ulazni podaci ovise o vrsti opreme koja se nalazi u mreži [98]. Skupljanje ulaznih podataka se odvija pomoću sustava SCADA u kojem se nalaze liste alarma (KRD) koje prikazuju stanje opreme u mreži. Alarmi su diskretni podaci simboličke (lingvističke) tj. kvalitativne prirode te su za njihovo korištenje idealni ekspertni sustavi (ES) [16, 31, 37, 42, 49]. ES se dijele na prvu generaciju koja bazu znanja formira pomoću pravila (engl. rule-based) i ES druge generacije koji bazu znanja formiraju na bazi modela (model-based) [65, 121]. Prva generacija ES za dijagnozu kvara bazu znanja je formirala na bazi iskustva, ali i na kombinaciji iskustva i poznavanja sustava što je dalo slabije rezultate. Bazu znanja kod takvih sustava bilo je teško provjerit, a o točnosti baze ovisi kvaliteta same dijagnoze kvara [1, 3, 5]. Druga generacija ES bazu znanja formira pomoću funkcioniranja i strukture (engl. function and structure) te pravi revolucionaran napredak u pogledu preciznosti i kvalitete dijagnoze [46, 50, 52, 118, 119]. Znanje korišteno u prvoj generaciji ES naziva se plitkim (engl. shallow knowledge), a kod druge generacije ES se naziva duboko znanje (engl. deep knowledge) [121, 142]. ES druge generacije[137] koriste kvalitativne informacije i kvalitativne modele (dinamički sustav je opisan pomoću funkcioniranja i strukture, a ne pomoću diferencijalnih

jednadžbi), a opis sustava na takav način dolazi iz znanstvenog područja UI koje se naziva kvalitativno zaključivanje (engl. qualitative reasoning) [16, 37, 103, 104, 105, 106, 108, 110, 112, 113, 117, 118, 120, 123, 124, 136, 138, 142, 145]. Sam ES koristi i uvozi metode koje su razvijene u području kvalitativnog zaključivanja. ES za dijagnozu kvara i restauraciju posjeduju manjak generalnosti u primjeni što se u ovakvom opsežnom i kombinatornom problemu ne smatra negativnom stranom, jer se od sustava zahtijeva: razumijevanje, fleksibilnost i visoke performanse [39, 77, 160]. ES emulira rješenje što znači kako je rješenje puno jače i bliže realnosti od rješenja dobivenog simulacijom [5, 30, 39, 50, 72]. Međutim i dalje se teško prevladavaju određeni problemi kao što su: nedostaci ili potpuni nedostatak informacija, kvantificiranje identifikacije kvara te odmak od crno-bijelog razmišljanja. Za takvu vrstu problema izrazito su pogodni sustavi s neizrazitom logikom (engl. fuzzy rule based expert system). Primjećeno je kako neizraziti sustavi koji za dijagnozu kvara koriste informacije u obliku statusa releja i prekidača ne upotrebljavaju vremensku oznaku alarma te bazu znanja ne iskazuju pomoću funkcionalnog djelovanja releja i prekidača [146, 147, 148, 149, 150, 151, 152, 153, 154, 155]. Istraživanje će se u ovoj disertaciji bazirati na rješavanju tog problema.

1.1 Temeljni cilj i plan istraživanja u disertaciji

Temeljni cilj istraživanja je izrada off-line sustava s neizrazitom logikom čiji se model temelji na funkcionalnom djelovanju releja i prekidača prikazanom u vremenu (koristeći vremensku oznaku alarma), a služio bi za dijagnozu kvara i pomoć pri odlučivanju u distributivnoj mreži. Predloženi sustav s neizrazitom logikom sastojao bi se od tri cjeline: vršio bi dijagnozu na bazi ispravnog funkcioniranja komponenti i sustava (dijagnoza iz prvog principa), dijagnozu na bazi otkazivanja funkcioniranja komponenti te dijagnozu na bazi krivog rada komponenti. Dijagnostički sustav uzima u obzir kvarove telemetrije (modeliraju se nepostojeće informacije). Identifikacija kvara će se odrediti i kvantificirati pomoću hibridnog alternativnog operatora unije [150, 156, 157, 159]. Sustav za off-line dijagnozu kvara razvit će se pomoću programskog jezika Prolog korištenog u znanstvenom području umjetne inteligencije [73, 78, 94, 96, 97]. U konačnici cilj je razvijeni off-line sustav za dijagnozu provjeriti na 8 primjera te konkretno primijeniti na situaciju parcijalnog raspada (engl. brownout) distributivne mreže Elektroslavonije.

1.2 Znanstveni doprinosi istraživanja

1. Novi pristup u dijagnozi kvara releja i prekidača pomoću neizrazite logike.
   - Novi način modeliranja funkcionalnih djelovanja releja i prekidača (ispravno djelovanje, krivo djelovanje i otkazivanje djelovanja) pomoću neizrazite logike u vremenskoj domeni.

2. Novi pristup dijagnozi kvara telemetrije pomoću neizrazite logike.
   - Novi pristup modeliranju nepostojećih informacija (nepostojeći signal isključenja i stanje zatvorenog prekidača) pomoću linearne funkcije.

3. Identifikacija kvara pomoću hibridnog operatora unije u neizrazitoj logici.
   - Novi alternativni operator unije iskazan je kao aritmetička sredina Hamackerovog i Schweizerovog operatora unije.

1.3 Organizacija i struktura doktorske disertacije

Disertacija se sastoji od osam poglavlja:

- Prvo poglavlje predstavlja problematiku te daje okvir znanstvenog područja kojim se bavi ova disertacija. Navode se određene neželjene situacije i problemi koji se pojavljuju u elektroenergetskoj mreži prilikom parcijalnog ili potpunog raspada sustava. Ističe se problem dijagnoze kvara koji odgovara na temeljno pitanje „ što se i gdje dogodilo u elektroenergetskoj mreži“. Obrazlaže se temeljni cilj i plan te definiraju doprinosi istraživanja.

- Drugo poglavlje predstavlja pregled literature u znanstvenom području istraživanja kojim se bavi ova disertacija.

- Treće poglavlje predstavlja i definira problem dijagnoze kvara. Dat je opis dijagnoze i primjena kod ekspertnih sustava. Predočena je struktura dijagnoze i njena potreba u elektroenergetskom sustavu.

- Četvrto poglavlje predstavlja ekspertne sustave kao zasebnu cjelinu. Prikazana je njihova domena u znanstvenom području umjetne inteligencije te razvojni put kroz

povijest. Definirana je njihova struktura i principi samog razvoja ekspertnih sustava. Predočeni su načini pretraživanja koje koriste ekspertni sustavi.

- Peto poglavlje prezentira neizrazitu (više-vrijednosnu) logiku i njene sustave. Prvenstveno prezentira kombinaciju neizrazite logike s ekspertnim sustavima. Predstavljeni su Sugeno i Mamdani modeli ekspertnih sustava pomoću neizrazite logike. Definirani su alternativni operatori kod neizrazite logike.

- Šesto poglavlje predstavlja ključni dio disertacije u kojemu se prezentira metodologija, logika i matematički opis dijagnoze kvara pomoću neizrazitog ekspertnog sustava (NES). Tu dolazi do sinteze relejne zaštite, ekspertnih sustava, dijagnoze kvara i neizrazite logike.

- Sedmo poglavlje prezentira rezultate istraživanja na osam primjera raznih situacija u mreži za koje je postavljena dijagnoza. Prikazana je primjena sustava za dijagnozu kvara na stvarnoj situaciji prilikom parcijalnog raspada elektroenergetske mreže Elektroslavonije.

- Osmo poglavlje daje zaključna razmatranja koja su proizašla kao rezultat ove disertacije te mogući budući smjerovi u istraživanju ovog znanstvenog područja.

2. PREGLED LITERATURE

Pregled literature bazira se na prvenstveno na knjigama, radovima iz časopisa (IEEE i drugih) i radova prezentiranih na konferencijama. Pregled literature koja obuhvaća područje istraživanja je podijeljeno u off-line i on-line ekspertne sustave za dijagnozu kvara. Svaka od tih cijelina nadalje se dijeli na:

- Ekspertne sustave na bazi pravila,
- Ekspertne sustave na bazi modela,
- Neizrazite ekspertne sustave.

Na samom završetku pregleda literature nalaze se ostali radovi iz bliskih znanstvenih područja koji obuhvaćaju problem dijagnoze kvara.

2.1 Ekspertni sustavi za dijagnozu kvara (off-line)

2.1.1 Ekspertni sustavi na bazi pravila

Fukui C. i Kawakami J. predstavili su ES prve generacije [1]. ES služi za otkrivanje sekcija u kvaru na temelju informacija (stanja) dobivenih od releja i prekidača. ES je namijenjen kao pomoć u dispečerskim centrima. Shahram B. J. at. al. predstavili su konceptualni ES prve generacije [5]. ES koristi informacije (stanja) prekidača i rastavljača kako bi konstruirao svoju dijagnozu. Kezunović M. i at. al. su predstavili konceptualni ES prve generacije koji u fazi dijagnoze osim na stanja prekidača i releja oslanja na analogne signale koje dobiva iz snimača kvara (engl. faultrecorder) [9]. Lou X. i Kezunović M. su predstavili konceptualni prototip ES prve generacije za dijagnozu rada releja [10]. ES se oslanja na podatke koji se nalaze u digitalnim relejima spremljenim kao fileovi i izvješćima koji su rezultat toga. Sauve at. al. predstavili su rad vezan za održavanje baze znanja kod procesora alarma [14]. Radna skupina D10 predstavlja potencijalne primjene ES u EES-u [15]. Daje dobar uvid u područje UI i područja koja pripadaju toj domeni. Subudhi B. i Swain A. K. predstavili su ES koji za dijagnozu koristi stablo kvara, a dijagnoza se odnosi na podsustav u elektrani. Stablo kvara se iskazuje pomoću pravila koja se unose u bazu znanja. Rad daje šture i površne smjernice bez ulaženja u dubinu [20]. Arya A. i Kumar Y. predstavljaju pregled tehnika koje se bave dijagnozom kvara u EES-u [25]. Rad obuhvaća tri

područja UI koja su primijenjena na problem dijagnoze kvara u EES-u: ANN, ES i GA. Liaccio T. E. at. al. pionirsko je djelo koje predstavlja logičku proceduru koja analizira prekidače i releje koji djeluju u EES-u [27]. Talkudar S. N. at. al. predstavili su konceptualni prikaz ES Faze 1 za simulaciju i dijagnozu [28]. Rad sadrži dobar uvod u samo područje te objašnjava problematiku koja će se rješavati. Talkudar S. N. at. al. predstavili su konceptualni pristup dva ES [29]. U radu su predstavljeni diskretni simulator događaja i ES za dijagnozu. Kirschen D. S. at. al. predstavili su ulogu ES za vrijeme izvanrednih stanja [31]. Balakrishnan R. i Pahwa A. predstavljaju konceptualni ES (off-line) za detekciju kvara [33]. Kao ulazne varijable u procesu dijagnoze koristi senzore za snimanje napona. Hsu Y. Y. at. al. predstavili su ES za lokaciju kvarova u distributivnoj mreži [34]. Pokušavaju obuhvatiti kvarove koji se nalaze između prekidača u VP i kupaca tako da ne postoje nikakve informacije o kvaru, jer te kvarove eliminiraju osigurači. Kaminaris S. D. at. al. predstavili su off-line ES koji ima namjenu korištenja u održavanju EE postrojenja [38]. Wollemberg B. F. at. al. predstavili su mogućnosti primjene UI u EES-u [39]. Sekine Y. at. al. predstavili su iscrpan pregled dijagnoze kvara u pogledu načina rješavanja(vrsta) implementacije i iskustva s terena [41]. Wollemberg B. F. predstavlja način prikaza i obrade alarma u procesoru alarma [42]. Prezentira rezultate koji potvrđuju mogućnost ES da se prikaže operatoru koncizne alarme koji su izvučeni iz standardnog skupa alarma [42]. Amelink H. at. al. predstavili su statičku i dinamičku metodu procesiranja alarma [43]. Rad se bavi obradom, prioritetima i podjelama alarma. Russell B. D. i Watson K. predstavili su ES s dvije funkcije a to su: dijagnoza početnog stanja kvara na principu generiranja šuma i otkrivanje starenja (propadanja) izolacije pomoću visokih frekvencija [54]. Scott W. G. predstavio je ES za restauraciju sustava na bazi telefonskih poziva [63]. Bell S. C. at. al. predstavili su ES za analizu performansi sustava zaštite [119]. ES je baziran na numeričkom modelu i analizi koja se obavlja off-line. Za analizu kao ulazni podaci koriste se podaci dobiveni sa snimača kvarova. Sakaguchi T. i Matsumoto K. predstavili su konceptualni ES za restauraciju EES-a koji se sastoji od simboličkog dijela (koji se bavi kombinatorikom, heuristikom) i numeričkog dijela koji računa tokove snaga [135].

2.1.2 Ekspertni sustavi na bazi modela

Rad Lee H. J. at. al. odnosi se na drugu generaciju ES, a implementirano je znanje koje se odnosi na topologiju, djelovanje pojedinih sustava zaštite i heuristiku [2]. Sidhu T. S. at. al. predstavili su abduktivnu tehniku zaključivanja kao model za dijagnozu u prijenosnoj mreži [47]. Ta se tehnika oslanja na funkcionalne i logičke odnose između elemenata u sustavu (vodovi, sabirnice, releji i prekidači) kako bi postavili dijagnozu [47]. Hertz A. at. al. predstavili su ES za decentraliziranu dijagnozu kvara u kojoj se koriste podaci iz releja [53]. Klein D. i Finin T. bave se pitanjem što je to duboki model i dubina modela [55]. Navode razliku između plitkog i dubokog modela [55]. Jorge R. D. at. al. predstavili su ES za dijagnozu kvara u distributivnoj mreži [58]. ES je baziran na modelu, a koristi se za analizu poslije kvara (engl. post morten) tj. u off-line modu rada. Park Y. M. at. al. predstavili su ES na bazi koncepta koji radi u off-line modu [60]. Predstavljeni ES bazu znanja kreira pomoću Booleove algebre i logičkih operacija. Za dijagnozu kvara koristi samo stanja releja. Ovakav ES naziva se (LBES) na bazi logike. Bau D. Y. at. al. predstavili su off-line ES na bazi modela za dijagnozu sustava za nadzor i nadziranog EES-a [62]. Foxvog D. i Kurki M. predstavili su odličan pregled ES i razlike između off-line, on-line i real time ES [65]. Kneale J. B. predstavio je primjenu ES na bazi stabla odlučivanja [66].

2.1.3 Neizraziti ekspertni sustavi

Khedher M. Z. predstavlja pregled primjene UI u području EES-a. Klasificira primjenu neizrazite logike na određene situacije i probleme u EES-u [11]. Monsef H. at. al. predstavili su FES za dijagnozu kvara u EES-u [146]. U radu modeliraju podatke sa SCAD-e uzimajući u obzir šumove i podatke kojih nema. Modelira se krivi rad releja i prekidača te jednostruki i višestruki kvarovi. Kao informacije za dijagnozu se koriste samo statusi releja i prekidača (bez oznake vremena). Jarventausta P. at. al. predstavili su FES za lokaciju kvara koristeći informacije sa SCAD-e (struje KS, djelovanje detektora kvara) te također informacije o vremenu [148]. Meza E. M. at. al. predstavili su rad koji testira alternativne operatore unije prilikom određivanja lokacije kvara [150]. Chang C. S. at. al. prikazali su FES za lokaciju sekcija u kvaru realiziranog pomoću objektnog orijentiranog programiranja na principu hijerarhijske strukture [147]. Cho H. J. i Park J. K. predstavili su off-line FES za dijagnozu kvara u prijenosnoj mreži pomoću sagitalnih dijagrama [153]. Min S. W. at. al. predstavili su off-line FES za dijagnozu kvara u prijenosnoj mreži [155]. Baza znanja je

formirana pomoću sagitalnih dijagrama na principu promjene topologije kao posljedice uzroka djelovanja releja i prekidača promatranog kao vremenskog slijeda događaja. Sustav je pokazao izrazite performanse te se može primijeniti kao on-line sustav za dijagnozu kvara i pomoć pri odlučivanju operatera [155].

2.2 Ekspertni sustavi za dijagnozu kvara (on-line)

2.2.1 Ekspertni sustavi na bazi pravila

Girgis A. A. i Johns M. B. razvili su on-line konceptualni hibridni ES što je iskorak naprijed u pogledu konceptualnih ES [3]. Cardozo E. i Talkudar S. N. razvili su također on-line hibridni ES koji koristi kompliciranu statistiku kako bi doskočio problemu manjka alarma [4]. Yongli Z. at. al. predstavili su on-line ES koji je u fazi testiranja [6]. Vazquez at. al. predstavili su on-line ES koji koristi informacije prekidača i rastavljača kako bi emulirao svoje dijagnoze [7]. Nuang Y. C. predstavio je novi pristup i drugačiji tip organizacije znanja u samoj bazi ES. Predstavljen je on-line ES koji vrši dijagnozu na bazi informacija o prekidačima te konačnu odluku produbljuje sa stanjem releja [8]. Kyriakides E. at. al. predstavili su teorijski prikaz nove generacije alarmnog procesora [12]. Rad prikazuje određene mogućnosti zamišljenog procesora alarma koji je u ranoj teorijskoj fazi. Kimura T. at. al. predstavili su praktični ES koji će biti priključen u Shikoku (Japan) [16]. ES je organiziran na način da se djelovanje releja bazira na zonama štičenja i vremenu okidanja, a sve zajedno je smješteno u bazi podataka izvan samog ES. Protopapas C. A. at. al. predstavili su konceptualni ES za dijagnozu kvara i procesiranje alarma koji može raditi u off-line i on-line režimu [17]. Tomsovic K. at. al. predstavili su ES za on-line dijagnozu u dispečerskom centru vezan na prijenosnu mrežu [18]. Tomsovic K. at. al. predstavili su konceptualni prikaz ES kao pomoć prilikom kvara u EES-u koji je spreman za rad u on-line režimu, ali još nije testiran [21]. ES koristi znanje dobiveno isključivo od dispečera. Yeyasurya B. at. al. predstavili su Tip 1 ES za dijagnozu EES-a (prijenosnoj mreži) [30]. U radu se predstavlja decentralizirani pristup ES koji je namijenjen za dijagnozu u TS, nakon čega se dijagnoza šalje u dispečerski centar. Marathe H. Y. at. al. prezentira on-line ES pod nazivom CRAFT koji je unaprijeđen s dodatnim bazama znanja [35]. Koronen J. J. predstavlja on-line ES na bazi modela [36]. Autor koristi kombinaciju softweara za tokove snaga i pravila koja su definirana na principu uzročno posljedičnih veza među alarmima. Tesch D. B. at. al. predstavili su on-line ES za dijagnozu kvara koji je smješten na zasebnom računalu [44].

Minakawa T. at. al. predstavili su on-line ES koji ima mogućnost dijagnoze kvara i restauracije [45]. Značajka ovog ES je što koristi vrijeme i kronološki slijed prilikom zaključivanja i donošenja odluka. Eickhoff F. at. al. predstavili su on-line ES za analizu kvara (dijagnozu) u distribucijskoj mreži [48]. Glavna značajka ovog ES je u tome što uzima u obzir dostupnost podataka (nepotpuni ili krivi podaci) kako bi prezentirao lokaciju kvara. Vale Z. A. i Moura A. M. predstavljaju on-line ES za procesiranje alarma u upravljačkim centrima [49]. Od dostupnih alarma pravi sintezu i prikazuje ih na organiziran i logički način. Znanje koje se nalazi u ES bazirano je na iskustvu koje je dobiveno od iskusnih operatera. Vale Z. A. i Moura A. M. predstavili su ES za analizu alarma u on-line izvedbi [59].

2.2.2 Ekspertni sustavi na bazi modela

McDonald J. R. at. al. predstavili su dva ES koja služe za procesiranje alarma i dijagnozu kvara [37]. Oba ES (Respond i APEX) su u on-line načinu rada te koriste metodu hipoteza na način na koji će biti predstavljena dijagnoza kvara. Wagenbauer M. P. i Nejdl W. prikazuju on-line ES koji se sastoji od modela i heuristike [50]. Struktura znanja podijeljena je u nekoliko razina gdje se na dnu nalaze modeli, a što se ide više u hijerarhiji koristi se heuristika. McArthur S. D. J. at. al. predstavili su ES za analizu rada zaštite pomoću modela [52]. U ES kombiniraju znanje (knowledge based reasoning) i model (model based reasoning). Predstavljena su dva ES gdje prvi ima naziv „APEX“ , a drugi „Respond“. Bernard J. P. at. al. predstavili su real time ES za dijagnozu kvara [117]. ES je baziran na modelu pod nazivom „Language“.

2.2.3 Neizraziti ekspertni sustavi

Lee H. J. at. al. predstavili su on-line FES za dijagnozu kvara [149]. Poznata je uzročno-posljedična veza između kvara i pripadnog releja te između releja i odgovarajućeg prekidača [149]. Kao metodu zaključivanja koristi uzročno-posljedični dijagram. Chen W. H. at. al. predstavili su on-line FES za dijagnozu kvara na principu uzročno posljedične veze i fuzzy logike [152]. Kako bi došli do dijagnoze koriste se statusi releja i prekidača te struje i naponi dobiveni sa SCAD-e. Rad autora Tan J. C. at. al. predstavili su on-line FES za dijagnozu kvara [154]. Kao ulazne podateke koristi statuse releja i prekidača.

2.3 Druga područja primjene i druge metode

Lee J. W. at. al. predstavili su gotovo rješenje tj. procesor alarma u nuklearnoj elektrani u Južnoj Koreji [13]. Chung D. T. i Modarres M. predstavili su ES za dijagnozu eksperimentalnog nuklearnog reaktora [102]. Kim I. S. i Modarres M. predstavili su ES za nadzor i analizu alarma u nuklearnoj elektrani [103]. Davis R. at. al. predstavili su postupak dijagnoze koji se bazira na opisu strukture i funkcioniranja kod digitalne elektronike [104]. Kim I. S. at. al. predstavili su ES na bazi modela za dijagnozu sustava za opskrbu vodom u nuklearnoj elektrani [111]. Nelson W. R. predstavili su ES za dijagnozu i tretman kod nuklearnih reaktora [120]. Edstrom F. i Soder L. predstavljaju novu numeričku metodu u restauraciji EES-a. Metoda se bazira na principu djelovanja frekvencije kvara pojedinih komponenata kako bi se izračunala vjerojatnost nekontrolirane sparacije komponenti (nekontroliranog raspada) [19]. King P. J. H. predstavlja odličan prikaz tablica odlučivanja [22]. Kowalski R. A. predstavlja povijesni pregled začetka, razvoja i nastanka logičkog programiranja tj. Prologa kao programa [23]. Faria L. at. al. predstavljaju simulator za obuku (osposobljavanje, treniranje) operatera za dijagnozu kvara i restauraciju EES-a [24]. Jenkins L. at. al. predstavljaju automatizirani način koordinacije zaštite u pogledu povećanja performansi EES-a [26]. Burnett A. D. at. al. predstavljaju snimače kvara u ranoj fazi dok su bili još kao stand-alone komponenta [32]. Wollenberg B. F i Sakaguchi T. u svom radu navode prednosti ES pred konvencionalnim programina [39]. Smith H. L. i Modzelowski T. J. predstavili su RTU mogućnosti i sposobnosti kako bi poboljšali EMS [40]. Dahlgren R. at. al. predstavili su sintezu alarma pomoću procesora alarma kod transformatora na bazi modela [46]. Zaključivanje na bazi modela (engl. model-based reasoning) predstavlja novi pristup kod procesora alarma [46]. Cheng S. J. at. al. predstavili su ES za kontrolu napona i reaktivne snage [51]. Sajja P. S. at. al. predstavljaju ES za dijagnozu abdomena (medicina) [56]. McArthur S. D. J. i Davidson E. M. predstavili su automatiziranu dijagnozu kvara (post fault diagnosis) na principu više agenata [61]. Bain M. at. al. predstavili su konceptualni prikaz ES za dijagnozu hidrauličke opreme [64]. Kezunovic M. at. al. predstavili su vodič kroz automatsku analizu kvara [98]. Hamscher W. predstavio je automatiziranu dijagnozu koja se bazira na strukturi i funkcioniranju [105]. Genesereth M. R. prezentira automatsku dijagnozu kvara opreme na bazi hijerarhijskog dizajna [106]. Chen J. S i Srihari S. N. predstavili su dijagnozu na bazi strukture i ponašanja [107] pod nazivom „lista kandidata“. Družovez M i Šostar A. predstavili su dijagnostički sustav u medicini na bazi modela [109]. Laffey T. J. at. al. predstavili su ES za Dijagnozu elektroničke opreme [108]. Prikazali su kako se ES može

poboljšati korištenjem strukture i funkcioniranja uređaja. Mline. R. predstavio je ES za dijagnozu analognih krugova [110]. Leinweber D. predstavlja primjenu ES u svemiru [116]. Kupiers B. predstavlja metodu kvalitativnog zaključivanja koja predviđa ponašanje mehanizama koji su karakterizirani s kontinuiranim vremenskim promjenjivim parametrima [123]. Rieger C. at. al. predstavili su koncept fizičkih mehanizama deklarativno, a simulaciju vrše proceduralno [124]. Barrow H. G. predstavio je program koji pokušava dokazati ispravnost digitalnog dizajna pod nazivom Verify [125]. Forbus K. D. predstavio je teoriju kvalitativnih procesa [127]. Reiter R. predstavio je teoriju dijagnoze pomoću prvog principa [128]. Hamscher W. predstavio je dijagnozu koja proizlazi iz strukturnih i funkcionalnih informacija [129]. Dijagnoza se odnosi na elektroničke sklopove. Picardi C. predstavila je pregled kroz dijagnozu na bazi modela [130]. Bredeweg B. Struss P. predstavili su pregled značajki, tema i glavnih fokusa u kvalitativnom zaključivanju [131]. Williams B. C. i Kleer J. predstavili su kvalitativno zaključivanje o fizičkim sustavima [132]. Huang Y. C. at. al. predstavili su hijerarhijski koncept dijagnoze kvara u prijenosnom sustavu [132]. Rad se bazira na korištenju modela s više razina i više ulaza te jednim izlazom kao zamjena za ANN. Prince W. R. at. al. predstavili su istraživanje na osnovi pretjeranog broja alarma za vrijeme poremećaja u kontrolnim centrima [134]. Clancey W. J. predstavio je bazu znanja kao kvalitativne modele [136]. Fink P. K. at. al. predstavli su razliku između plitkog i dubokog znanja koje se upotrebljava u ES kod dijagnoze [67]. Malandian E. at. al. predstavili su konceptualni prikaz off-line ES koji služi u dijagnozi akceleratora čestica u nuklearnoj elektrani [100]. Ivanov V. at. al. predstavili su ES za dijagnozu kvarova u (TS) [99]. ES kao organizaciju zaključivanja koristi stablo kvara. Kleer J. i Williams B. C. predstavili su način konstrukcije razmišljanja za dijagnozu kod višestrukih kvarova u digitalnoj elektronici [101]. Lapp A. S. i Powers G. J. razvili su program za automatsku sintezu stabla kvara [112]. Henly E. J. i Kumamoto H. odnosi se na [112] u smislu dopune i neslaganja vezano za izneseni reducirani skup (engl. cut-set) stabla kvara [113]. Lambert H. E. osvrt je na [112] te predstavlja rješenje koje daje jednostavniji i razumniji algoritam za sintezu stabla kvara [114]. Operator Xor nepotreban je s inženjerskog pogleda [114]. Yellman T. W. osvrt je na rad [112] te govori o problemu koji je nastao zbog korištenja Xor operatora [115]. Beschta A. at. al. predstavili su ES na bazi modela za lokaciju kvarova u prijenosnoj mreži [118]. Sustav je prezentiran opisiujući ponašanje individualnih komponenti i strukture sustava (npr. interakcijski put između komponenti) [118]. Yoon W. C. i Hammer J. predstavili su dijagnozu kvara pomoću dubokog zaključivanja kroz nekoliko različitih pristupa [121]. Davis R. predstavio je dijagnostičko zaključivanje bazirano na strukturi i ponašanju [122]. Dijagnoza

se odnosi na digitalne elektroničke čipove. Consolel L. i Dressier O. predstavili su pregled teorije i primjene dijagnoze na bazi različitih modela [126]: strukturni (obuhvaća fizičku ili logičku strukturu uređaja), funkcionalni (opisuje funkcioniranje uređaja), ponašanja (opisuje kako uređaj radi, npr. kako dolazi do svojih funkcija) ili kombinaciju. Reggia A. J., at. al predstavili su dijagnostički ekspertni sustav koji je proizašao iz modela dijagnoze opisane pomoću skupova [141].

3. DIJAGNOZA KVARA

3.1 Razlozi za dijagnozu kvara u elektroenergetskom sustavu

Od samih početaka uvođenja SCADA sustava za nadzor, kontrolu, mjerenje i zaštitu dolazi se do stanovitog zaključka kako se pri aktivaciji određenog sustava zaštite slijeva bujica alarma koje operateri nisu u stanju obraditi. Samim tim zbog razloga nedostatne obrazovanosi, manjka daljnjeg usavršavanja i manjka situacijskog treninga na simulatorima ukazuje se potreba za određenom vrstom pomoći. Kod savladavanja ovakvih problema sa strane računalnog aspekta pomoć u takvim situacijama može biti u obliku interaktivnog programa (ES) ili u obliku on-line sustava (procesor alarma) [77]. Dijagnoza kvara (engl. Fault diagnosis) ima primarni zadatak da identificira kvarove na opremi u EES-u. Zadatak sustava zaštite je da štiti primarno postrojenje od kvarova. Prilikom aktivacije zaštite šalju se signali vezani uz stanje zaštite i prekidača u dispečerski centar i lokalno u TS. Krovni sustav SCADe nadzire funkcioniranje primarnog i sekundarnog dijela sustava. Tako prikupljeni podaci dolaze na KRD i tamo ostaju trajno pohranjeni. Iz aktivnosti signala zaštite i prekidača može se utvrditi o kojem je kvaru riječ i gdje se nalazi premda se može raditi o izrazito složenoj situaciji. Dijagnoza kvara uključuje [77]: identifikaciju kvara, kvarove na prekidačima, kvarove na zaštiti i kvarove telemetrije. Kvarovi na prekidačima obuhvaćaju krivo ili nikakvo djelovanje. Kvarovi telemetrije obuhvaćaju manjak alarma koje je teško predvidjeti. Uzmemo li u obzir postojanje viška alarma ili uopće upitnost pojedinih dolazimo u područje kaosa što baš i nije primjenjivo na našu situaciju. Dijagnoza kvara se samo površinski može učiniti kao trivijalan zadatak [77]. Razlozi za dijagnozu kvara su različiti, ali dijagnoza sama po sebi je vremenski zahtjevna. Dijagnozu kvara možemo svrstati u trenutnu, kratkoročnu i dugoročnu [77]. Prvenstveni zadatak operatera koji se nalaze u dispečerskom centru (DC) je trenutno postavljenje dijagnoze kako bi se moglo pravilno reagirati i uspostaviti moguće uklopno stanje (restauracija EES-a). Kratkoročnu dijagnozu mogu postaviti i ljudi koji se bave zaštitom u EES-u. Situacija nakon kvara gdje dolazi do odvajanja dijela elektroenergetske mreže, a nakon toga treba uslijediti identifikacija kako bi se mogla uspostaviti pravodobna i moguća restauracija EES-a. Operater prije restauracije mora identificirati kvar kako bi uz odgovarajuću proceduru upravljanja izvršio proces restauracije EES-a. To je izrazito važno gdje su velika područja mreže ostala u mraku zbog krivog ili uopće ne djelovanja zaštite i prekidača kako bi što manje kupaca ostalo bez električne energije i tako se smanjili financijski gubici. Kada se radi o kratkoročnoj dijagnozi najčešće se radi o krivom djelovanju ili nedjelovanju zaštite i prekidača. Ta otkrića najčešće govore

kako je potreban detaljan pregled zaštite i prekidača u smislu ispravnosti. O statističkim podacima se ažurno i točno mora brinut kako bi se koristili u dugoročnoj analizi performansa pojedine mreže ili postrojenja. To je posao koji se mora voditi svjesno i dugoročno budući kako kvarovi i kriva djelovanja pojedinih dijelova EES-a nisu baš tako česta pojava. Često puta su prekidači i zaštita u vezi sa SCADA sustavom te je u DC njihova aktivnost poznata. Tako operater u DC preko alarma (signala koji dolaze od zaštite i prekidača) koji predstavljaju vidljivi dokaz indikacijom za kvarove koje fizički ne vide [77]. Također mjerenja struje i napona čiji se podaci prenose putem SCADA sustava mogu koristit kod dijagnoze kvara premda nisu u direktnoj vezi [77]. Sliku o kvaru mogu upotpuniti i snimači poremećaja. Također novije vrste releja imaju mogućnost zapisa nešto prije, za vrijeme i trenutak poslije kvara tako da se i to može iskoristiti kod kratkoročnih dijagnoza. Uobičajeno je da dijagnozu kvara provode operateri u DC i inženjeri koji se bave zaštitom, ali gledajući vremenski za njihovu analizu potrebno je neko vrijeme. Kompanije i operateri traže softwearski alat (program) koji bi im služio kao pomoć zbog vrlo zahtjevnog zadatka koji je podložan neprestanoj promjeni. Postoji ogroman problem optimiranja između dodavanja novih alarma kako bi se dobila što bolja slika o sustavu i reduciranja alarma koji nisu neophodni za uvid u stanje ne trenu. Razvojem SCADA sustava i povezivanje sa što većim brojem uređaja dovodi na ekran ogroman broj alarma koje operateri nisu u stanju interpretirati, jer su došli do granica svojih mogućnosti. Sustav koji ima mogućnost obuhvaćanja što više čimbenika (alarma) ima mogućnost korekcije te je učinkovitiji. Razvoj staničnih i drugih računala omogućio je lakšu implementaciju sustava orijentiranih na baze znanja. Tehnike koje koriste sustavi s bazama znanja (ES) daju dobra temelj za razvoj dijagnoze kvara u EES-u, zbog velike količine znanja i simboličke prirode samog zadatka. U početku su se sustavi nazivali automatski sustav za analizu grešaka. Nigdje se nije spominjala umjetna inteligencija pa se zato kaže kako se iz ovakvih ideja sve razvilo. Sustav se aktivira na bazi alarma prekidača i zaštite. Sustav nije pravio nikakvu dijagnozu dok su alarmi pristizali nego tek kad je dolazak alarma bio gotov, jer se sustav više nije mijenjao koristio je posljednji status mreže i povijest alarma koja se nalazila u bazi. Kvarove identificira uspoređujući isključene prekidače s alarmima releja. Krivo djelovanje zaštite i prekidača rješava se logičkim pravilima. Ovaj koncept je bio odskočna daska za mnoge sustave koji su koristili bazu znanja. Prvi sustavi koji su se razvijali u kasnim 80-tim godinama bazirani na tim idejama, a razvijeni su u Prologu. Identifikacija dionice u kvaru, kvar prekidača ili zaštite, krivo djelovanje zaštite ili prekidača bazira se na već spomenutoj ideji podataka o isključenju prekidača i radu pojedine zaštite. Osnovna bit lokacije kvara je u tome kako kvar mora biti u

okviru crnog područja (engl. Blackout area). Pojedinačna područja kvara (identifikacija kvara) su određena zonom štićenja pojedinog releja, a točno identificiran kvar je u sjecištu zona štićenja pripadnih aktivnih releja. Pomoću automatiziranih pravila područja se automatski izvode. Kada postoje više crnih područja sumnja se na višestruke kvarove, a najvjerojatnija sekcija u kvaru je ona koja ima najmanje krivih i potpuno otkazanih djelovanja zaštite.

3.2 Struktura dijagnoze kvara u elektroenergetskom sustavu

Dijagnoza kvara današnjih sustava se razlikuje od prvih sustava po tome što su današnji sustavi automatizirani (procesori alarma) jer dobivaju informaciju direktno od SCAD-e. Prvi sustavi su bili interaktivnog tipa gdje je čovjek komunicirao s dijagnostičkim sustavom. Veličina današnjih sustava znatno se povećala, a samim tim i količina alarma, zaključaka i broj konfiguracija. Obrada podataka kod procesora alarma je brža i efikasnija, jer ne zahtijeva interakciju između korisnika i ES. Procesori alarma su gotov proizvod kojeg je moguće kupiti na tržištu, a zahtijeva milione $ uložene u razvoj. Dijagnozu kvara sačinjava više odgovora (dijagnoza, skup rješenja) koji moraju biti činjenično opravdani što je alternativa jednom apsolutnom rješenju [77]. Sustav za dijagnozu kvara u današnje vrijeme je povezan sa svime i svačime zbog velike razgranatosti distributivne mreže. Postoji mogućnost istovremenih kvarova ili vremenskih bliskih te se na neki način mogu pojaviti više dijagnoza koje se možda preklapaju u pojedinim dijelovima. Također se zbog veličine sustava može pojaviti istovremeno nekoliko zasebnih kvarova koji svaki za sebe ima nekoliko mogućih dijagnoza. Dijagnoza kvara nije konstanta sama po sebi te je podložna značajnijim promjenama prilikom pojave novih činjenica [77]. Dijagnostički zaključak se formira na bazi tri hijerarhijska sloja [77]:

- Poremećaj svaki za sebe zahvaća određenu konfiguraciju mreže ili određenu zonu te zbog same blizine ili preklapanja zona štićenja mogu nastati određeni problemi. To znači kako svaki poremećaj može imati više mogućih zona i različite konfiguracije mreže. Kako bi se to izbjeglo područje pogođeno kvarom izvodi se direktno iz topologije.
- Scenarij su moguća alternativna objašnjenja istog kvara. Scenarij je širi pojam koji obuhvaća više dijagnoza (parcijalnih scenarija).

- Više slučajnih poremećaja tvore scenarij, a to su: kvarovi u sustavu, kvarovi na opremi, lažna prorada i telekomunikacijski problemi.

Kvarovi u sustavu govore da li se radi o jednostrukom ili višestrukom kvaru te da li je kvar prolazan ili je trajnog tipa. Otkazivanje opreme se većinom svodi na zaštitu i prekidače koji nisu djelovali. Krivo (lažno) djelovanje se događa onda kada to nije očekivano (potrebno). Otkazivanje opreme se bazira na tome kako je boljka nastala prilikom uočavanja kvara ili nije došlo do djelovanja nekog elementa u lancu sustava zaštite (relej šalje signal, a prekidač zataji). Kvarovi telemetrije odnose se na aktivnosti koja se dogodila, ali za nju ne postoji alarm. Na dva faktora treba obratiti pozornost kod samog razvoja dijagnoze kvara, a to je sveobuhvatnost i detalji. Ti faktori su u kontradikciji te treba pronaći zajednički optimum kako bi dijagnoza bila što obuhvatnija uz dovoljnu količinu detalja. To se rješava hijerarhijskom podjelom baze znanja [77]:

- Površinska dijagnoza daje prvu impresiju baziranu na alarmima. Aktivnost u mreži se otkriva pomoću dijagnostičkog znanja temeljenog na ručnom upravljanju. Alarmi koji su posljedica automatske aktivnosti služe kod povezivanja stanja mreže s poremećajem. Znanje izgrađeno u površinskoj dijagnozi koristi se dalje u središnjoj (centralnoj) dijagnozi.
- Središnja (centralna) dijagnoze obavlja najveći posao te obuhvaća: identifikaciju kvara, kvarove zaštite, kvarove prekidača i kvarove telemetrije. Obuhvaća različite strategije (filozofije) kako bi se odredila dijagnoza kvara.
- Dubinska dijagnoza koristi rangirane scenarije koje je odradila centralna dijagnoza te produbljuje samu dijagnozu. Kako bi se produbila dijagnoza koriste se dublji odnosi u ponašanju EES-a, znanje koje nije električnog tipa (termičko ili neko drugo) te se uspoređuje sa scenarijima prijašnjih događaja. Također koriste se struje i naponi iz mikroprocesorskih releja i snimača kvarova (engl. disturbance recorders).

Strategije pretraživanja koje koristi dijagnoza kvara [77]:

- Strategija čekanja (engl. wait and see) koristi alarme releja i prekidača te čeka dok se pojedino područje potpuno ne izolira te onda u tom području nastoji pronaći moguće kvarove koji su odgovorni za nepoznato područje (engl. brownout/blackout area). Traži releje koji su aktivirali prekidače koji okružuju crno područje. Koriste se podaci

iz on-line SCAD-e (alarmi releja i prekidača). Strategija čekanja prvenstveno je vođena prekidačima. Ova strategija ima manjkavosti, jer mora dobiti sve alarme vezane za prekidače kako bi bila uspješna pa se zbog toga razvila strategija hipoteza.

- Strategija hipoteza ne čeka sve alarme releja i prekidača, jer uzima u obzir kako se određeni alarmi neće ni pojaviti. Za svaki kvar u sustavu određeni relej mora djelovati te se mora pojaviti određena (pripadajuća) skupina alarma ako se radi o stvarnom kvaru. Također se koriste informacije dobivene sa SCAD-e (alarmi releja i prekidača). Strategija se oslanja na vođenje alarmima releja te se može nositi s nestalim alarmima na način da dodjeli određenoj hipotezi neki oblik nesigurnosti. Za razliku od strategije čekanja koja mora imati sve alarme, strategija hipoteza pretpostavlja kvar na bazi jednog alarma kojeg slijedi te se tako stvara slika o području koje je pogođeno kvarom ne čekajući da se izolira u mreži nego se slika o području kvara stvara slijedeći alarme releja i prekidača.

3.3 Metode za dijagnozu kvara u elektroenergetskom sustavu

Metode koje se koriste za dijagnozu kvara su brojne, a one koje se primjenjuju u EES-u mogu podijeliti na metode koje koristi čovjek i metode koje koristi računalo. Metode za dijagnozu kvara koje koristi čovjek su [71,]:

- Metoda niza (engl. fingerprint approach) dobila je ime iz načina na koji alarmi stižu u upravljački centar. Alarmi se nižu jedan na drugi tako da je najgornji alarm zapravo zadnji događaj koji se dogodio. Metoda niza koristi se zaključivanjem unaprijed. Zaključivanje počinje sa skupljanjem informacija iz kojih se izvode logički zaključci. Zaključivanje počinje s poznatim činjenicama iz kojih se izvode novi zaključci koristeći logička pravila i tako se nastavlja proces sve dok se na dođe do željnog cilja. Nedostatak kod zaključivanja unaprijed je u tome što krećemo od informacija ili činjenica koje često nemamo pa se zaključci ne mogu pravilno izvesti.
- Metoda hipoteza se bavi drugom vrstom problema u kojoj informacije (činjenice) nisu poznate pa kreće od hipoteza koje se nastoje dokazat sakupljanjem informacija koje ih podupiru.

ES se koriste ovakvim načinom zaključivanja koji se još naziva zaključivanje unatrag. Zaključivanje unatrag počinje s ciljem kojeg treba dokazat. Metoda hipoteza je alternativni pristup analiziranja alarma koji se pojavljuju u mreži i postrojenju. Metoda niza se koristi

onda kada je situacija prilično jasna (do stotinjak alarma), a metoda hipoteza koristi se onda kada nismo u mogućnosti sa 100% sigurnošću reći što se dogodilo. Broj hipoteza u samom početku se može popeti do čak desetak. Formiranje među-hipoteza je riskantno i rijetko se koristi u čovjekovoj analizi alarma. Pregledavanjem KRD-a neke hipoteze će otpasti, a na kraju u pravilu ostaje dvije ili tri hipoteze. Metoda hipoteza je upravo način na koji funkcioniraju programi za dijagnozu kvara i procesori alarma. Obje metode su jednostavne ali njihova primjena je kompliciranа [71,]. Računalne metode mogu se podijeliti u klasične i metode umjetne inteligencije [160, 161, 162]:

- Klasične metode (numeričke) baziraju se na provjeri granične vrijednosti nekih važnijih mjernih varijabli [161]. Metode ne dozvoljavaju dubinsku dijagnozu i ne simuliraju ljudsko razmišljanje [161]. Klasični način detektiranja kvara sastoji se od provjere mjerene veličine sustava u odnosu na toleranciju i slanje alarma kada je ta tolerancija prijeđena [161]. To su tehnike procesiranja (obrade) signala koje se koriste procjenom stanja, procjenom parametara, adaptivnim filtriranjem, referentne varijable, statističkom teorijom odlučivanja i analitičkim redudantnim metodama [161]. Klasične metode koriste se odnosima između struje i napona, a koriste se i energetskim sadržajem signala [160]. Neke od klasičnih metoda su [160, 161, 162]: Metoda mjerenja impedancije, metoda putujućeg vala, metoda viših harmonika, metoda trenda i metoda analize opterećenja.

Metode umjetne inteligencije za dijagnozu kvara [160]:

- Ekspertni sustavi (ES) su izrazito pogodni za rješavanje dijagnostičke vrste problema. Ulazni podaci su simboličke prirode. Podrazumijeva se interaktivni proces između korisnika i računala. Odnosi između ulaza i izlaza su jasni (logički) definirani pomoću funkcionalnog i strukturnog znanja kako bi se izbjegli problemi prve generacije ES. Točnost ES je 100% [25].

- Neuronske mreže (engl. neural networks) koriste numeričke podatke kako bi donijeli odluku o dijagnozi kvara. Odnos ulaza i izlaza je praktički nepoznat (crna kutija). Dobra strana toga je to što sustav može biti približno opisan. Loša strana je u tome što je neuronsku mrežu potrebno utrenirat što je izrazito vremenski zahtjevno, a također treba odabrati i odgovarajuću metodu treninga. Pozitivna strana je što neuronska mreža posjeduje mogućnosti učenja i prilagodbe. Točnost u odnosu na ES je manja, a

ponekad su rješenja krajnje upitna [25]. Neuronske mreže nisu u stanju objasniti rješenje i nisu pogodne za on-line upotrebu [161].

- Neizrazita logika (više-vrijednosna ili engl. fuzzy logic) je metoda koja se bavi modeliranjem nepreciznosti, nesigurnosti kod donošenja odluka [160]. Poboljšava i povećava potencijal kod modeliranja ljudskog razmišljanja koje koristi lingvističke varijable [160]. Koristi se dvjema različitim metodama opisa modela [160]:

    1. Uzročno-posljedična pravila opisuje pomoću lingvističkih varijabli,
    2. Zakon prijenosa (odnos ulaza i izlaza) opisani su pomoću običnih algebarskih jednadžbi.

Neizrazita teorija je u suprotnosti s klasičnom teorijom vjerojatnosti, jer je prva deterministička, a druga stohastička u naravi. Teorija vjerojatnosti se koristi bi-vrijednosnom logikom (0 ili 1), a neizrazita teorija je više-vrijednosna te može poprimiti bilo koju vrijednost između 0 i 1. Nudi jednostavan pristup rješavanju kod nejasnih, neprecizni, izobličeni i nepostojećih ulaznih informacija [162].

3.3.1 **Optimizacijske metode za dijagnozu kvara**

Rješavanje problema dijagnoze kvara u EES-u pomoću optimizacijskih metoda je moguće. Optimizacijske metode za dijagnozu kvara u EES-u su [84]: evolucijski algoritmi (genetski algoritmi kao podskup), tabu pretraga (engl. tabu search), SWARM optimizacija, kolonija mravi (engl. ant colony), kolonija pčela (engl. bee colony), simulirano žarenje (engl. simulated annealing). Pojavljuje se kontradikcija između stohastičkih metoda i determinističkog problema dijagnoze kvara [162]. Također genetski algoritam (GA) ne garantira uspjeh zbog stohastičke prirode, a kod nekih primjena genetski bazen može biti daleko od rješenja [162]. Ako su varijable velike i ograničenja zahtjevna za dolazak do rješenja potrebno je puno vremena [163]. Kako bi GA u primjeni na dijagnozu kvara bili točniji i efikasniji potrebno je još puno istraživačkog rada [25]. Od optimizacijskih metoda u rješavanju problema dijagnoze kvara najviše uspjeha ima Tabu pretraga koja posjeduje potencijal za on-line primjenu [84].

3.3.2 Hibridne metode za dijagnozu kvara

Trendovi pokazuju kako se rješenja vezana za problem dijagnoze kvara idu u smjeru kombiniranja simbolički i numeričkih informacija [161]. Za takvu vrstu kombinacije podataka koriste se hibridne metode. Prednosti i nedostaci pojedinačnih metoda prikazani su u tablici 3.1.

Tablica 3.1: Usporedba pojedinih metoda

Svojstva metoda	ES	NN	FL	GA
Prikaz znanja	5	1	5	1
Nesigurnost	1	5	5	5
Nepotpuni podaci/Aproksimacija	1	5	5	5
Adaptacija/Generalizacija	2	5	2	5
Mogućnost učenja	2	5	2	5
Interpretacija	5	1	5	1

Deterministička priroda dijagnoze kvara zahtijeva od metode da se unaprijed odrede poznate stvari (modeliranje znanja i razmišljanja, interpretacija). Iz tablice 3.1 vidljivo je kako svaka metoda ima jače i slabije strane, no pojedinačno gledano ES uz svoje slabije strane su ipak najbolje rješenje [161]. Kako bi metode bile što efikasnije i točnije rješenje se traži u hibridnim metodama. Hibridne metode podrazumijevaju kombiniranje najmanje dvije osnovne metode prikazane u tablici 3.1. Neke od uspješnijih kombinacija za dijagnozu kvara su [151]:

- Neuronski sustavi (neuronske mreže + ES, engl. Neural system),
- Neizrazite neuronske mreže (FS+NN, engl. fuzzy neural network),
- Neizraziti ekspertni sustavi (FS+ES, engl. fuzzy rule based system),
- Neizraziti neuronski sustavi (FS+NN+ES, engl. fuzzy neural system).

3.4 Nesigurnost prilikom dijagnoze kvara

Nesigurnost ima značajnu ulogu u mnogim područjima elektrotehnike pa tako i u dijagnozi kvara. Ponekad se za određeni kvar ne može dati jedna dijagnoza nego se daje nekoliko alternativa. Legitimni razlozi za više dijagnoza kod jednog kvara su [77, 164]: gubitak alarma, nepojavljivanje alarma kod potpunog otkazivanja uređaja. Ograničenja

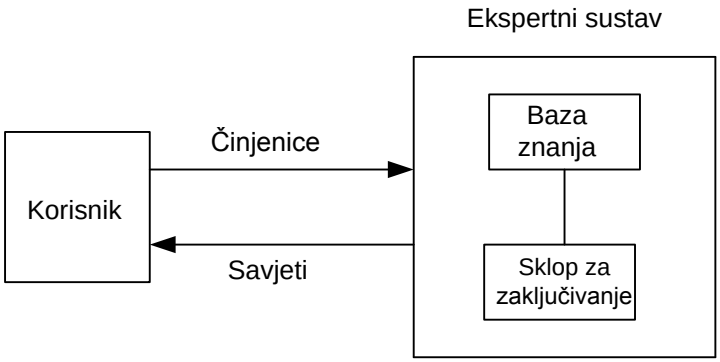
sustava SCAD-e obzirom na činjenicu kako nisu svi releji spojeni na SCAD-u tako da je i prikupljanje dokaza nepotpuno. Tehnike koje se bave nesigurnošću razvijale su se tijekom godina [77, 164]:

- Teorija vjerojatnosti (klasična vjerojatnost) je najstarija i datira još u 17. st.. Nepostojanje statistike, ali i kvaliteta statistike koju vode dispečeri je nedostatna i vrlo upitna zbog raznovrsnosti posla i nekih subjektivnih neracionalnih odluka [164]. Mnogi su istraživači zbog takvih i sličnih razloga zaključili kako je klasična teorija vjerojatnosti neadekvatna i zaostaje u odnosu na druge teorije [164].
- Teorija subjektivne vjerojatnosti se primjenjuje tamo gdje ne postoje statistički podaci, a želi se iskazati nesigurnost. U prošlosti se vrlo često koristila zajedno s ES. Problem kod subjektivne vjerojatnosti je što se ona vrlo teško postavlja bez obzira koliko stručnjak ima znanja i iskustva zbog rijetkosti i raznolikosti događaja [164]. Prvi komercijalni ES PROSPECTOR koristio je subjektivnu vjerojatnost.
- Dampster-Shafer teorija razvija se tijekom 60-tih i 70-tih god. 20. st.. Teorija se razvila zbog dva problema [164]: kako prikazati nešto što ignoriramo i subjektivna vjerojatnost dodijeljena događaju i negacija tog događaja moraju dati jedan.
- Teorija faktora sigurnosti (engl. certainty factor) je često primjenjivana u kombinaciji s ES. Faktor sigurnosti je iskazan s CF, a kreće se od - 1 za negaciju do + 1 za potvrdu [164]. Teorija je primjenjivana na ranije ES poput MYCIN [164].
- Neizrazitu teoriju skupova (engl. fuzzy set theory) razvio je 1965. god. Lofti Zadeh. Za razliku od ostalih metoda ona je deterministčkog karaktera. Vrlo lako i jednostavno iskazuje nepotpune, nejasne, neprecizne i nepostojeće informacije i odnose. Teorija mogućnosti je više-vrijednosna i može poprimiti bilo koju vrijednost između 0 i 1.

4. EKSPERTNI SUSTAV

4.1 Uvod

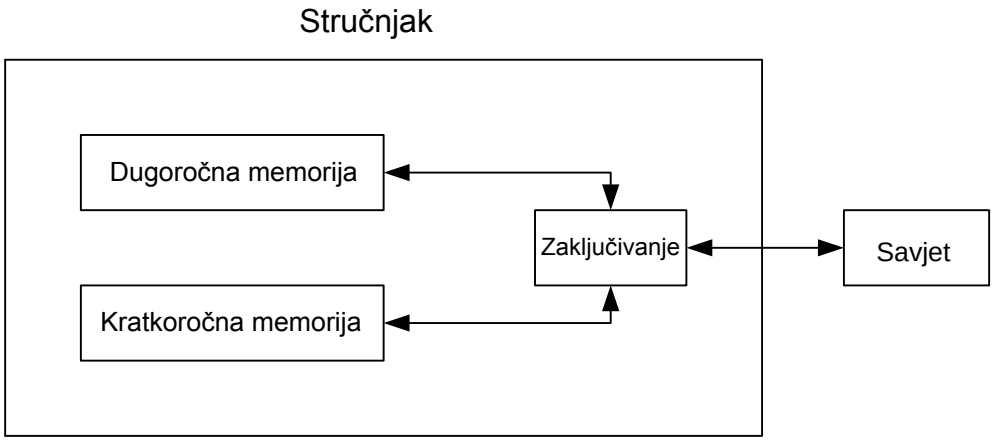
Ekspertni sustav (ES) je program koji oponaša rad stručnjaka u određenom području promatranja [72]. Umjetna inteligencija (UI; engl. Artificiall intelligence) široko je znanstveno područje u koje pripada i ES kao podskup (domena). Umjetna inteligencija se koristi kod rješavanja mnogih današnjih problema. ES može biti interaktivan ili automatiziran, a koristi se u mnogim područjima znanosti, istraživanja, elektrotehnike, prava, medicine itd. ES se koriste činjenicama kako bi izveli zaključke, a taj zaključak u kombinaciji s drugim činjenicama izvod sljedeći zaključak. ES emulira zaključak stručnjaka u određenom području promatranja. Emulirati znači biti bliže realnosti te je pojam puno snažniji od simulacije [54, 72, 79, 88, 99]. Za razvoj ES potrebni su stručnjak za domenu (engl. domain expert), stručnjak za bazu znanja (engl. knowledge base expert) i programer za određeni programski jezik. Ponekad je potrebno uključiti i četvrtu osobu, ako je potrebno prevođenje u C++. Sustav s bazom znanja (engl. knowledge base system) i ES su potpuno istog značenja. Koncepcija osnovnog interaktivnog sustava je da na bazi činjenica korisnik dobije savjet ili ekspertni odgovor slika 4.1.



Slika 4.1: Osnovni ekspertni sustav

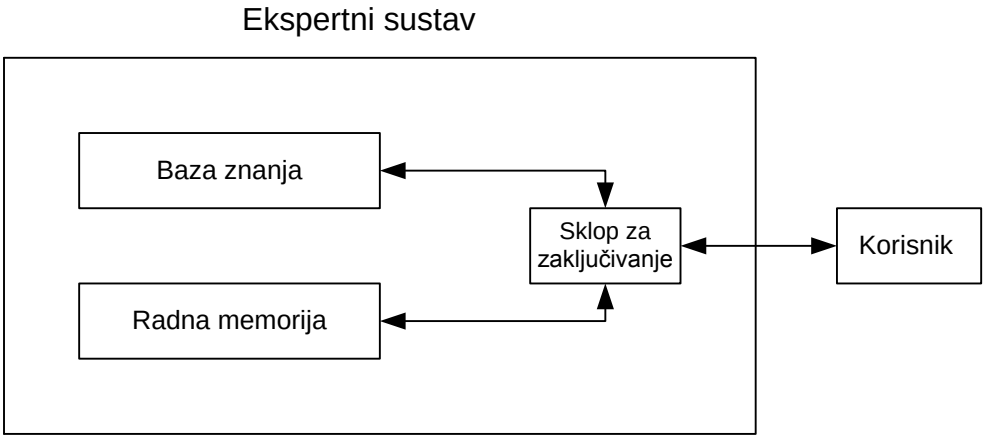
4.2 Struktura ekspertnog sustava

Strukturu ES objasnit ćemo preko paralelne usporedbe sa stručnjakom i njegovim načinom razmišljanja. Stručnjak posjeduje kratkoročnu i dugoročnu memoriju te vrši sintezu kroz razmišljanje, a samim tim iznosi zaključak ili daje savjet što prikazuje slika 4.2.



Slika 4.2: Proces ljudskog razmišljanja

ES konstruiran je na bazi imitacije ljudskog razmišljanja, a sastoji se od: baze znanja, sklopa za zaključivanje (engl. inferenc engine) i radne memorije što prikazuje slika 4.3.



Slika 4.3: Ekspertni sustav s pripadajućim cjelinama

Čovjekov način razmišljanja bazira se na principu znanja i iskustva koje se nalazi u dugoročnoj memoriji i informacija koje pohranjuje u kratkoročnu memoriju. Kombiniranjem obiju memorija čovjek donosi zaključak (daje savjet). ES u bazi znanja ima pohranjeno znanje iz određene domene, a u radnu memoriju sprema činjenice koje su nastale upitom (interakcijom) između ES i korisnika. Sklop za zaključivanje kombinira i uspoređuje znanje i činjenice te izvodi zaključak (daje prijedlog korisniku).

- Baza znanja (engl. knowledge base) je u biti dugoročna memorija u kojoj se pohranjuje znanje iz određene domene. Zadatak stručnjaka za konstruiranje domene (engl. knowledge engineer) se svodi na prikupljanje znanja od stručnjaka iz određenog područja i prebacivanje ga u program s nekom od poznatih tehnika. Znanje se prezentira pomoću if-then pravila koje povezuju uzrok i posljedicu tj. uvjet i akciju.
- Činjenice unesene iz interaktivnog procesa nalaze se u radnoj memoriji (engl. working memory). ES uspoređuje činjenice s bazom znanja (engl. knowledge base) te izvodi nove zaključke koje odlaze u radnu memoriju i proces se ponavlja. Čovjekova kratkoročna memorija se kod ES predstavlja pomoću radne memorije. Činjenice nastale interaktivnim procesom i izvođenjem u samom ES nalaze se u radnoj memoriji.
- Ljudsko razmišljanje oponaša se pomoću modula za zaključivanje (engl. inference engine). Ključna uloga modula za zaključivanje se bazira na uspoređivanju činjenica u radnoj memoriji s znanjem u bazi znanja kako bi se izveli određeni zaključci o nekom problemu. Zaključci se spremaju u radnu memoriju te se nastavlja istraživanje na novim zaključcima.
- Interakcija između korisnika i ES odvija se pomoću sučelja (engl. interface). Sučelje se koristi menijima, grafikom, ekranima na dodir sve kako bi se olakšala interakcija.

$$A(\text{algoritam}) = L(\text{logika}) + K(\text{kontrola}) \tag{4.1}$$

ES se razlikuje od konvencionalnih programa po tome što je kod njih odvojeno znanje od upravljanja(kontrole) [23]. Kod standardnih programa se isprepliće znanje i kontrola tog znanja što kod promjene koda može poremetiti jedno i drugo. Kod proceduralnih jezika vrlo se teško razlučuje što je znanje, a što upravljanje. ES se jednostavno održava zbog odvojenosti znanja i upravljanja. Opća relacija za algoritam iskazana je relacijom (4.1) gdje je kod ES k = konstanta, a L se mijenja [23].

4.3 Prikazivanje baze znanja

Prikupljeno znanje mora se prebaciti u program te strukturno prikazati u određenom obliku. Tu dolazi do izražaja rečenica ″znanje je moć″ [76]. Znanje se može razvrstati u više kategorija [76]:

- Proceduralno znanje se koristi za opis načina rješavanja problema.
- Deklarativno znanjem se iskazuje poznato o problemu.
- Meta znanje se koristi u manipuliranju s već postojećim znanjem.
- Heurističko (plitko) znanje se svodi na iskustvo i metodu pokušaja i pogrešaka.
- Strukturnim znanjem se predstavlja model (koncept, kreacija).

Strukture kojima se prikazuje znanje [72, 76]:

- Činjenice se mogu iskazati jednoznačno ili višeznačno te sadrže trostruko svojstvo (objekt, atribut, vrijednost). Činjenice se mogu iskazati pomoću jednostruke ili višestruke vrijednosti. Nesigurnost činjenica se kvantificira pomoću faktora sigurnosti, vjerojatnosti ili neizrazitih skupova (engl. fuzzy sets).
- Pravila su jedna od najvažnijih struktura za prikazivanje znanja. To je struktura kojom se povezuju činjenice iz kojih proizlaze određeni zaključci, dijagnoze, usmjerenja i preporuke. Pravila su iskazana pomoću načela ″ako uvjet zadovoljen onda zaključak″ (if-then) u najjednostavnijem obliku. Pravila se mogu formirati pomoću više uvjeta (engl. multi premise) i različitih logičkih operatora (and, or, else). Pravila se mogu koristiti za rješavanje određenih procedura (if uvjet then akcija). Pravila iskazana u ″if-then¨ obliku mogu imati dodatak u obliku faktora sigurnosti, vjerojatnosti, ali i biti iskazana pomoću neizrazite logike. Od faktora sigurnosti i vjerojatnosti u sklopu pravila se odustalo zbog nedostataka. Meta pravila se koriste u kombiniranju već postojećeg znanja kako bi sustav bio učinkovitiji i efikasniji, a hijerarhijski se nalaze iznad standardnih pravila.
- Semantičke mreže su metoda prikazivanja znanja koja se koristi teorijom grafova. Graf se sastoji od čvorova koji predstavljaju objekte i strelica koje prikazuju vezu između tih objekata.
- Okviri (engl. shema) su produžetak i nadogradnja na semantičke mreže gdje je znanje prikazano u obliku kartice.

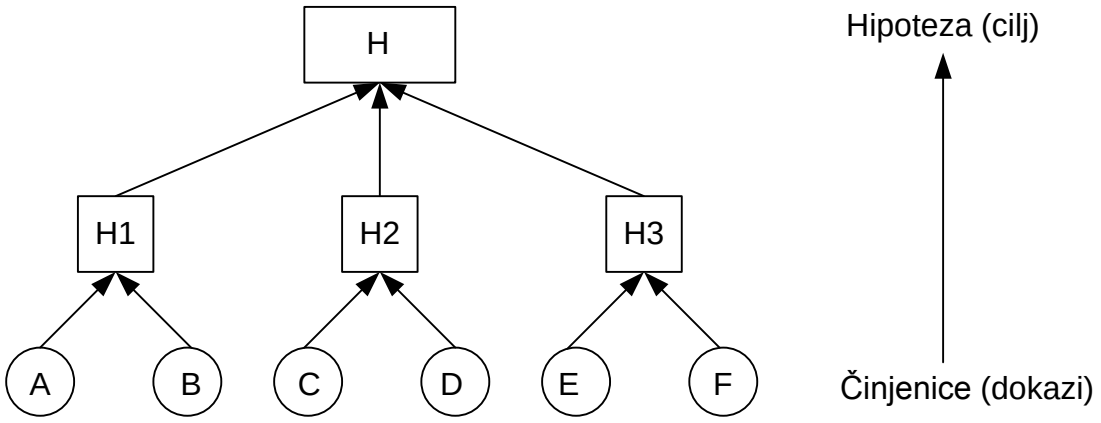
- Logika je najstariji način prikazivanja znanja te je uvedena i u svijet programiranja. Logika se razvija tijekom godina, a njena primjena u UI se skroz pokušava unaprijediti. UI najčešće se koristi propozicijskom i predikatnom logikom, a obje se koriste simbolima i logičkim operatorima kako bi se izveli potrebni zaključci.

4.4 Tehnike zaključivanja kod ekspertnih sustava

Razmišljanje se kod ES odvija pomoću modula za zaključivanje (engl. inference engine) koji barata tehnikama zaključivanja (engl. inference techniques). Zaključivanje se svodi na rad s činjenicama, znanjem i strategijama kako bi se došlo do zaključka kod određenog problema.

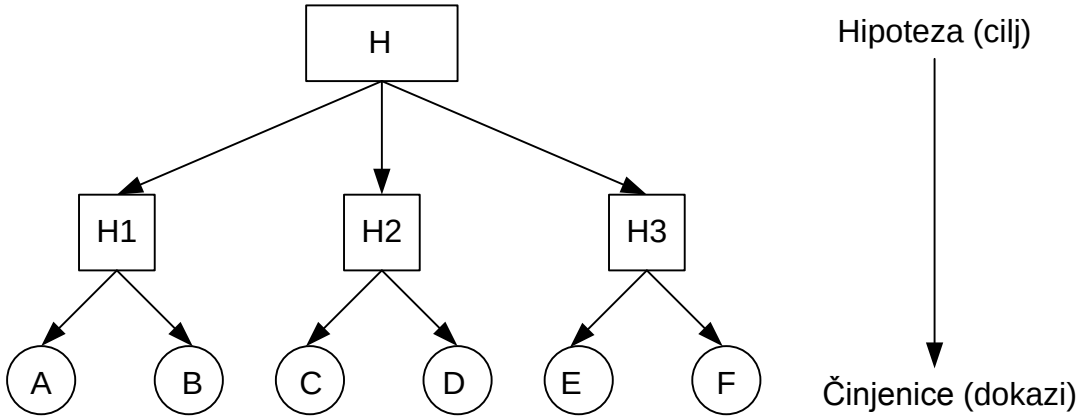
Tehnike zaključivanja kod ekspertnih sustava su[72, 76,]:

- Zaključivanje unaprijed (engl. forward chaining) se koristi poznatim činjenicama kako bi se izveo zaključak. Zaključivanje unaprijed ide od uzroka prema posljedici. Za zaključivanje unaprijed se kaže kako je ono zaključivanje odozdo prema gore (engl. bottom-up) što prikazuje slika 4.4.



Slika 4.4: Zaključivanje unaprijed

- Zaključivanje unatrag (engl. backward chaining) kreče od poznatog zaključka (hipoteze) te ide prema činjenicama što je u suprotnosti sa zaključivanjem unaprijed. Zaključivanje unatrag kreće od posljedice prema uzroku, a kaže se kako je takvo zaključivanje odozgo prema dolje (engl. up to bottom) što prikazuje slika 4.5.



Slika 4.5: Zaključivanje unatrag

5. NEIZRAZITA LOGIKA

5.1 Alternativni operatori u neizrazitoj logici

Neke od najvažnijih operacija na skupovima su: unija, presjek, komplement kako za klasične tako i za neizrazite skupove. Postoje standardne operacije s neizrazitim skupovima i alternativne operacije s neizrazitim skupovima [183]. T-norme (engl. triangular norms) su prikladne za iskazivanje presjeka u neizrazitoj (više-vrijednosnoj) logici [159]. Generalno t-norme i t-conorme se mogu reducirati jedna u odnosu na drugu [159]. Vizualizacija t-normi i t-conormi može biti na više načina [184]: 3D, površina u stranici kocke, prikazivanje samo kontura krivulja, dijagonalne sekcije itd.. Tako se presjek i unija mogu iskazati pomoću logičkih operatora I i ILI. Osnovni operatori kod neizrazitih skupova iskazani su relacijama (5.1) i (5.2):

$$\mu_{A\wedge B} = \min\left(\mu_A, \mu_B\right) \tag{5.1}$$

$$\mu_{A\vee B} = \max\left(\mu_A, \mu_B\right) \tag{5.2}$$

Međutim treba naglasiti kao to nisu jedini operatori pomoću kojih se mogu modelirati presjek i unija neizrazitih skupova [185]. U neizrazitoj logici presjek se naziva (t-norma), a unija (t-conorma ili s-norma) [185].

5.1.1 T-norme

Kako bi bilo koja funkcija zadovoljavala kao neizraziti presjek mora posjedovati određena svojstva koja osiguravaju da dobiven neizraziti skup pomoću funkcije **i** bude prihvatljiv kao značajan neizraziti presjek danog para neizrazitih skupova [156]. Funkcije koje posjeduju takva svojstava nazivaju se (t-norme) [156]. Funkcije koje predstavljaju klasu t-normi imaju ekvivalentno značenje kao i neizraziti presjeci [156]. Mogu se definirati kao funkcija s dvije varijable na intervalu [0, 1] ili kao binarna operacija na intervalu [0, 1] [159].

Def. t-norme [156, 187]

T-norma je funkcija dvije varijable **i**: [0, 1] x [0,1]→ [0, 1] koja za svaki a, b, d ∈[0, 1] zadovoljava barem sljedeće aksiome [156, 187]:

A1: i(a,1) = a (granični uvjet)

A2: $b \leq d \rightarrow i(a,b) \leq i(a,d)$ (monotonost)

A3: $i(a,b) = i(a,d)$ (komutativnost)

A4: $i(a, i(b,d)) = i(i(a,b), d)$ (asocijativnost)

Ova četiri aksioma predstavljaju osnovu neizrazitog presjeka (t-normi) [156]. Često se neizraziti presjeci (t-norme) ograničavaju s dodatnim uvjetima koji su poželjni, ali ne nužni [156]:

A5: i = kontinuirana funkcija (kontinuitet)

A6: $i(a,a) < a$ (subdempotency)

A7: $a1 < a2$ i $b1 < b2 \rightarrow i(a1,b1) < i(a2,b2)$ (striktna monotonost)

T-norme često korištene kao neizraziti presjek [156]:

- Standardni presjek: $i(a,b) = \min(a,b)$
- Algebarski produkt: $i(a,b) = a \cdot b$
- Povezana razlika: $i(a,b) = \max(0, a+b-1)$
- Drastični rez: $i(a,b) = \begin{cases} a & kada \quad b = 1 \\ b & kada \quad a = 0 \\ 0 & inačn \end{cases}$

Neke od mnogih t-normi su navedene u tablici [156].

5.1.2 T-conorme

Svojstva koja funkcija **u** mora zadovoljiti kako bi bila prihvatljiva kao neizrazita unija su upravo jednaka svojstvima funkcija koje se nazivaju t-conormama [156]. T-conorme ili neizarzite unije su ekvivalentni izrazi [156].

Def. t-conorma:

T-conorma je funkcija dvije varijable u: $[0, 1] \times [0,1] \rightarrow [0, 1]$ koja za svaki $a, b, d \in [0, 1]$ zadovoljava barem sljedeće aksiome [156, 187]:

A1: $u(a,0) = a$ (granični uvjet)

A2: $b \leq d \rightarrow u(a,b) \leq u(a,d)$ (monotonost)

A3: $u(a,b) = u(a,d)$ (komutativnost)

A4: $u(a, u(b,d)) = u(u(a,b), d)$ (asocijativnost)

Skup aksioma A1-A4 predstavlja osnovu neizrazite unije [156]. Dodatni aksiomi iskazani su [156]:

A5: u = kontinuirana funkcija (kontinuitet)

A6: $u(a,a) > a$ (superidempotency)

A7: $a1 < a2$ i $b1 < b2 \rightarrow u(a1,b1) < u(a2,b2)$ (striktna monotonost)

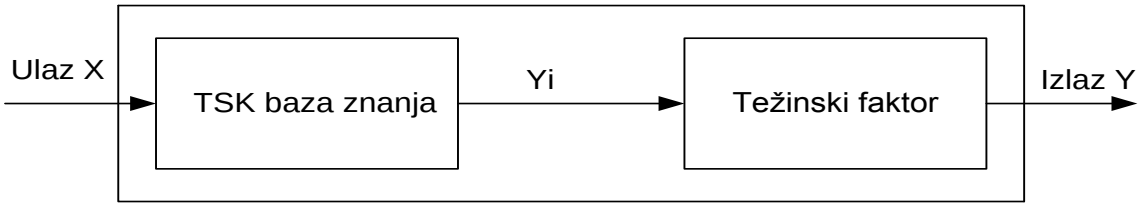
Prirodno neizrazita logika proširuje tablicu istine Booleove logike s parcijalnim istinama te to predstavlja najjednostavniju neizrazitu implikaciju [184]. Neke od familija krivulja t-normi i t-conormi [184]: Schweizer-Sklar, Hamacker, Frank, Yager, Dombi, Sugeno-Weber, Aczel-Alsina i Mayor-Torrens. Neke od mnogobrojnih t-conormi navedene su u [156]. Svojstvo dualne povezanosti t-normi i t-conormi iskazano je u [184].

5.2 Neizraziti ekspertni sustav

Mamdani i TSK (Takagi, Sugeno i Kang) su najčešća dva modela neizrazitih ekspertnih sustava (NES) [82, 158].

5.2.1 Sugeno model neizrazitog ekspertnog sustava

Sugeno model (NES) kao ulazne varijable koristi x i y, a za izlaznu varijablu koristi z. Z = f(x,y) je obična funkcija koja predstavlja posljedicu [82, 158]. Često je funkcija z = f(x,y) polinom, ali može biti i klasična funkcija dok god predstavlja izlaz sustava. Kada je z = konstanta to je Sugeno model nultog reda, a kada je z = linearna funkcija to je Sugeno model prvog reda itd. Kod Sugeno modela svako pravilo ima crisp izlaz (posljedicu) određenu funkcijom [82, 158]. Sugeno model je prikazan na slici 5.1.



Slika 5.1: Sugeno model neizrazitog ekspertnog sustava

Pravila kod Sugeno modela FES se iskazuju relacijom (5.3) [82, 158]:

$$\text{IF x je A AND y je B THEN z je f(x,y)} \tag{5.3}$$

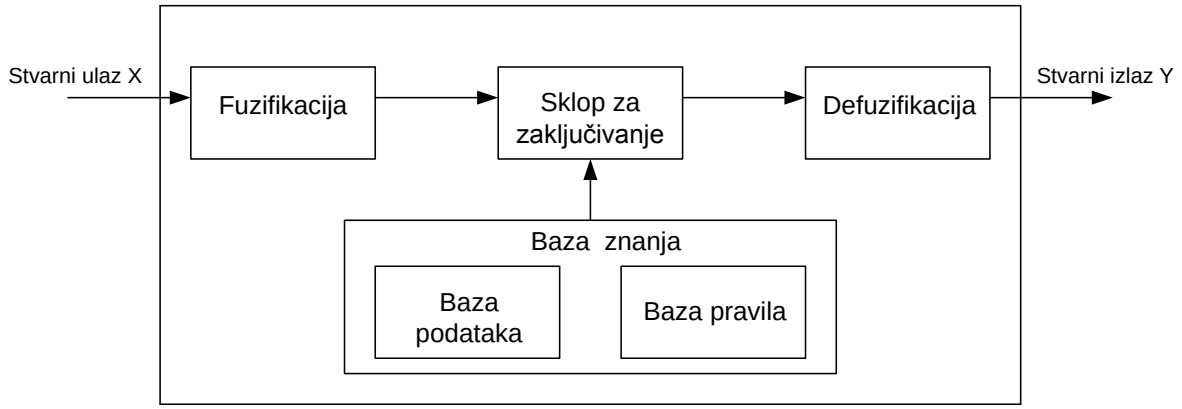
Izlaz TSK sustava u slučaju m pravila računa se pomoću težinskog faktora (5.4) [82, 158]:

$$Y = \frac{\sum_{i=1}^{m} h_i \cdot y_i}{\sum_{i=1}^{m} y_i} \tag{5.4}$$

Glavna prednost kod TSK modela što nije potrebna defuzifikacija što znatno olakšava sam dizajn sustava [82, 158]

5.2.2 Mamdani model neizrazitog ekspertnog sustava

Mamdani modeli koriste fuzifikaciju i defuzifikaciju (češće se nazivaju neizrazitim logičkim kontrolerima) [82, 158]. Dobili su ime po autoru koji je bio pionir u tom području, ali povijesno gledano prve primjene su na kontrolerima [82, 158]. Mamdani model se sastoji od baze znanja, sustava zaključivanja, fuzifikacije i defuzifikacije što je prikazano na slici 5.2 [82, 158].



Slika 5.2: Mamdani model neizrazitog ekspertnog sustava

Problem se formulira pomoću lingvističkih IF-THEN pravila [82, 158]. Mamdani model je prikladan za lingvističko modeliranje problema kontrole u sustavu (engl. system control) [82, 158]. Mamdani modeli se dijele na klasični (opisni, lingvistički) i na aproksimativni [82, 158]. Mamdani klasični sustav ima pravila oblika (5.5) [82, 158]:

$$\text{IF X1 je A1 and … and Xn je An THEN Y je B} \tag{5.5}$$

Aproksimativni Mamdani model ima istu strukturu kao i opisni (lingvistički). Jedina razlika je tip pravila u bazi znanja gdje u ovom slučaju pravila ne koriste lingvističke varijable nego direktno fuzzy varijable [82, 158]. Pravila kod aproksimativnog sustava iskazana su relacijom (5.6) [82, 158]:

$$\text{IF X1 je A1 and … and Xn je An THEN Y je B} \tag{5.6}$$

gdje su A i B neizraziti skupovi [82, 158].

5.3 Modeliranje nepostojećih informacija pomoću neizrazite logike

Postoji ogromna količina literature koja se bavi nepostojećim informacijama (NI), a razvijena je unazad 30 godina i predstavlja vrlo širok spektar pristupa modeliranju NI [169]. S nepostojećim informacija se postupa različito u različitim disciplinama, a čak se događa da i istraživači postupaju različito u istom polju istraživanja [169]. Postupanje s NI često nije evidentirano u istraživačkim radovima i člancima ili je stavljeno na margine bez da se prizna kako rezultati analize mogu direktno ovisiti o tome kako se postupa s NI [165]. Nepostojeće informacije su jedan od utjecajnih faktora u kvaliteti informacija. Neadekvatno baratanje nepostojećim informacijama može rezultirati odstupanjem u analizi ili dovesti do krivih

zaključaka [165]. Standardne statističke metode pretpostavljaju da za svaki slučaj postoje sve informacije potrebne za analizu [166]. Većina statističkih knjiga ne govori ništa o nepostojećim informacijama [166]. Statistički pristup problemu nepostojećih informacija je opće poznat te se slučaj koji ima nepostojeću informaciju jednostavno izostavlja iz analize [166]. Veza između uzroka i posljedice kod NI nazivaju se mehanizmom generiranja NI. Postoji tri različita mehanizma induciranja NI [165, 166, 167, 172, 176, 177, 181]: potpuni slučajni nedostatak informacija (MCAR; engl. missing compleatly at random), slučajni nedostatak informacija (MAR; engl. missing at random), nepostojanje informacija koje nije slučajno (NMAR; engl. Not missing at random je isto kao i MNAR; engl. Missing not at random).

Praktično rješavanje problema nepostojećih informacija (tretman nepostojećih informacija) se vrši pomoću sljedećih načina [165, 166, 170]:

- Brisanje ili odbacivanje dijelova gdje imamo NI je najjednostavniji pristup. Ovo je praktično kada imamo mali broj slučajeva i gdje ne dolazi do značajnih pogrešaka prilikom zaključivanja. Riskantno je ako se radi o informacijama visokog stupnja važnosti.
- Lažna nula (engl. dummy variable) je metoda koja koristi sve informacije koje su dostupne o nepoznatoj informaciji.
- Umetanje ili ubacivanje (engl. imputation) je metoda koja procjenjuje vrijednost i popunjava mjesto nepostojeće informacije. Ovo je najčešće korišteni pristup.

Metode umetanja se dijele na deterministčke i stohastičke. Deterministčke metode umetanja su [171, 172, 173, 174, 175]: približno ubacivanje, deduktivno ubacivanje, ubacivanje srednje vrijednosti, umetanje omjera, regresijsko umetanje, metoda najbližeg susjeda, metoda povijesnog umetanja, metoda predvidive usporedbe, sekvencijalno uređeno hot deck umetanje, logičko umetanje, Hot (cold) deck umetanje.

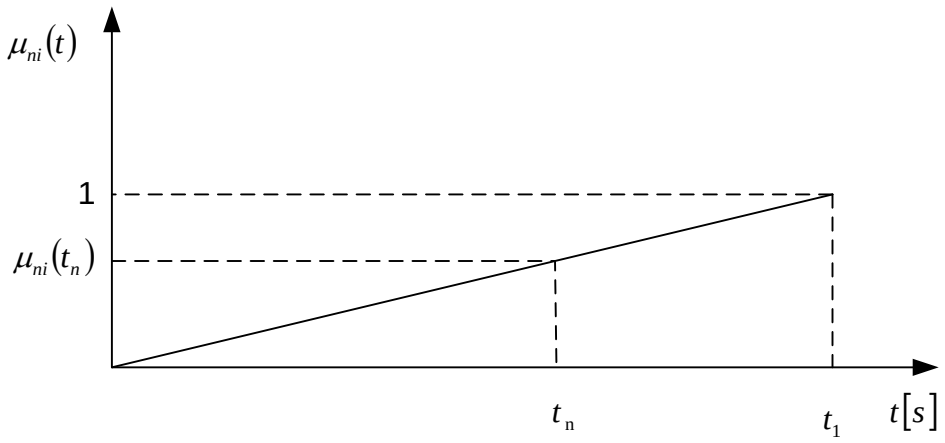
Stohastičko umetanje sastoji se od deterministčke metode plus dodana slučajna pogreška [171].

Pristup modeliranju NI pomoću tehnika UI i strojnog učenja u koje pripada i modeliranje NI pomoću neizrazite logike. Tehnike ubacivanja NI koje obuhvaćaju UI i strojno učenje su [180]: stabla odlučivanja, metoda najbližeg susjeda, metoda klastera, neuronske mreže, neizrazita logika, klasični skupovi. Također postoji čitav niz hibridnih tehnika koje

obuhvaćaju već navedene osnovne tehnike [165, 178]. Kod neizrazitih ekspertnih sustava modeliranje NI prikazano je u [146, 178, 179]. Nepostojeće informacije se također modeliraju pomoću funkcije pripadnosti kao i sve situacije u neizrazitoj logici kod neizrazitih ES. Oblici funkcije pripadnosti pomoću kojih je modelirana NI kod neizrazitih ES [146, 178]: konst = 0.5, trokut, trapez, gaussova krivulja. Budući da nemamo nikakav podatak o nepostojećoj informaciji razumno je pretpostaviti kako je moguć bilo koji oblik funkcije pripadnosti [178]. Modeliranjem NI pomoću neizrazite logike uvodimo nesigurnost u model što je izrazito poželjno. Modeliranje NI pomoću funkcije pripadnosti je deterministički model s različitim stupnjevima pripadnosti. Niti u jednom od postojećih radova [146, 178, 179] se ne spominje mehanizam generiranja NI. Međutim to se može vidjeti iz oblika funkcije pripadnosti. Nepostojeća informacija koja se modelira pomoću konst = 0.5 je modeliranje stohastike pomoću neizrazite logike, jer varijabla pripada 0.5, a ne pripada isto 0.5 skupu te je riječ o MCAR mehanizmu generiranja NI. Za ostale funkcije pripadnosti pomoću kojih se modelira nepostojeća informacija (trokut, trapez i Gauss) su vjerojatno kategorija MAR, budući da za NMAR moramo imati točan uvid u cijelu pozadinu problema što gotovo nigdje nemamo. Također postoji činjenica kako se ne može povući baš jasna granica između tih teorijskih mehanizama MAR i NMAR [176].

Novi pristup u modeliranju nepoznate informacije prikazuje se pomoću linearne funkcije pripadnosti $\mu_{ni}(t)$ u odnosu na vrijeme tj. pripadnost nepostojećem stanju se povećava prolaskom vremena što je prikazano relacijom (5.7) i slikom 5.3. Pozadina ovog modela sastoji se od kombinacije deduktivnog (logičkog) umetanja, regresijskog umetanja i longitudinalnog umetanja [172, 182] iskazanog u fuzzy logici.

$$\mu_{ni}(t) = \frac{t}{t_1} + a \tag{5.7}$$



Slika 5.3: Model nepostojeće informacije

Nepoznato vrijeme t_n određuje se defuzifikacijom pomoću relacije (5.8).

$$t_n = \frac{\int_0^{t_1} t \cdot \mu_{ni}(t)dt}{\int_0^{t_1} \mu_{ni}(t)dt} \tag{5.8}$$

5.4 Identifikacija kvara pomoću neizrazite logike

Identifikacija kvara se definira pomoću djelovanja releja i prekidača budući da releji i prekidači u kombinaciji štite točno određenu dionicu ili komponentu u EES-u. Poznavajući informaciju o djelovanju releja ili prekidača neposredno saznajemo na kojoj je dionici kvar budući da relej u kombinaciji s prekidačem štiti točno određenu dionicu. Ako imamo informaciju o releju i prekidaču to upotpunjuje dijagnozu i podiže izglede da se baš kvar nalazi na toj lokaciji. Identifikacija kvara definira se pomoću hipoteze koja čini uniju neizrazitih skupova svih prekidača i skupa svih releja koji su djelovali na bazi relacija (5.9-5.12) [147, 148, 151].

$$F_i = F_i(CB) \cup F_i(RL) = \left\{ C_i, \mu_{p(\,fault)}(C_i) / C_i \in S_{island} \right\} \tag{5.9}$$

$$P_{fault} = \{F_i\} \tag{5.10}$$

$$F_i(CB) = \left\{ C_i, \mu^{CB}_{p(\,fault)}(C_i) \right\} \tag{5.11}$$

$$F_i(RL) = \left\{ C_i, \mu^{RL}_{p(\,fault)}(C_i) \right\} \tag{5.12}$$

Jedna od mogućih sekcija u kvaru označena je s C_i, a neizraziti skup koji sadrži sve moguće kvarove s P_{fault}. Neizraziti podskup prekidača koji su djelovali označen je s $F_i(CB)$, a podskup releja koji su djelovali s $F_i(RL)$. Sekcije kvara C_i koje pripadaju neizrazitom skupu P_{fault} uzimajući u obzir samo prekidače koji su djelovali iskazujemo funkcijom pripadnosti $\mu^{CB}_{p(\,fault)}(C_i)$. Sekcije kvara C_i koje pripadaju neizrazitom skupu P_{fault} uzimajući u obzir samo releje koji su djelovali iskazujemo funkcijom pripadnosti $\mu^{RL}_{p(\,fault)}(C_i)$.

5.4.1 Identifikacija kvara pomoću alternativnih operatora

Identifikacija kvara u neizrazitoj logici određena je relacijom (5.9) što predstavlja mogućnost korištenje alternativnih operatora unije (t-conormi) za određivanje identifikacije kvara. Operator maksimuma korišten je za identifikaciju kvara u [146, 147, 149, 150, 152, 154]. Osim operatora maksimuma korišteni su Yagerov operator u [150, 153, 155], operator algebarske sume [148], Hamacker [150], Dubois [150] i Dombi [150].

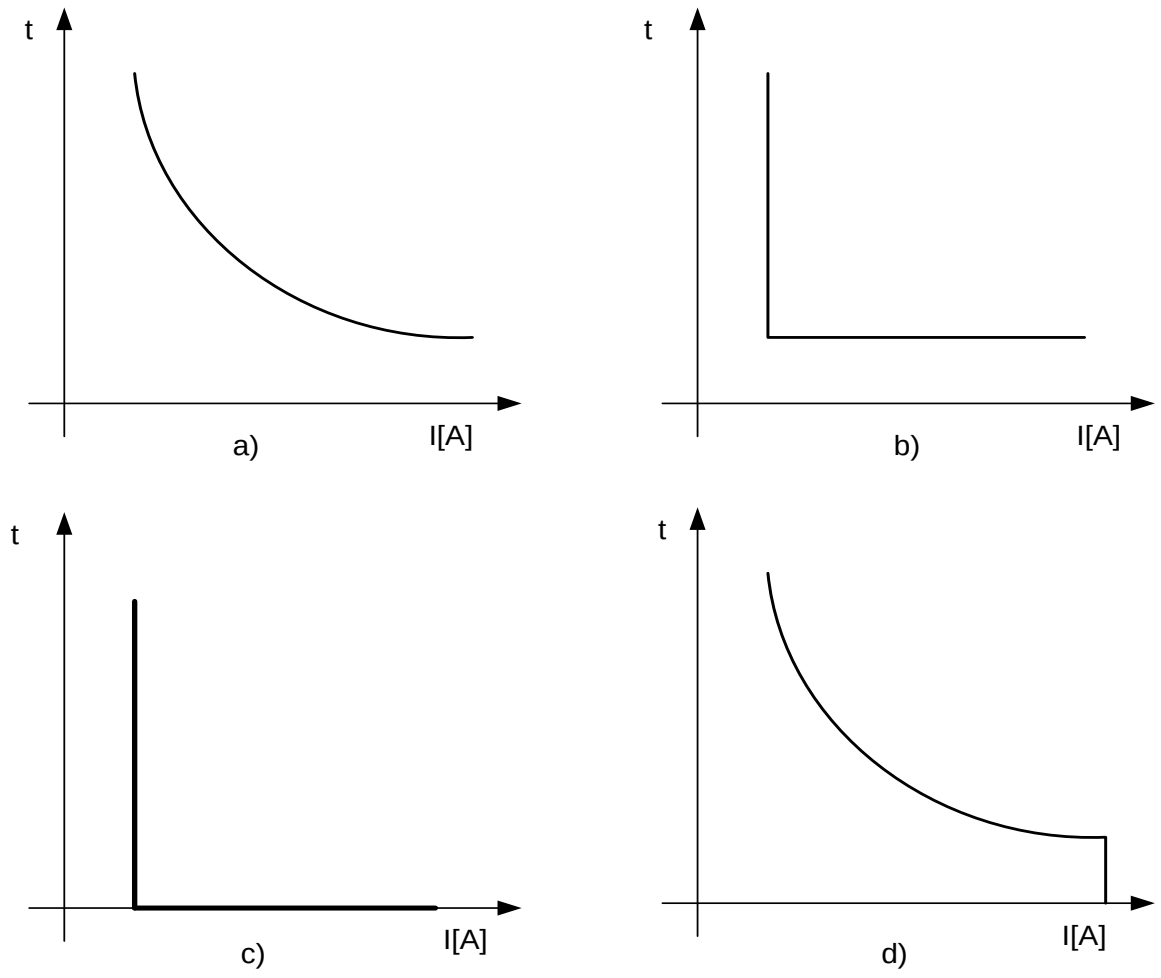
Identifikacija kvara bit će određena pomoću hibridnog operatora O (zadovoljava aksiome A1-A4 koji definiraju operatore) koji je iskazan kao aritmetička sredina Hamackerovog i Schweizerovog operatora (5.10).

$$O = u(a,b) = \frac{2a + 2b - 3ab - a^2 - ab^2 + a^2b^2}{2 - 2ab} = \frac{1}{2}(H + S) \tag{5.10}$$

6. METODOLOGIJA

6.1. Releji

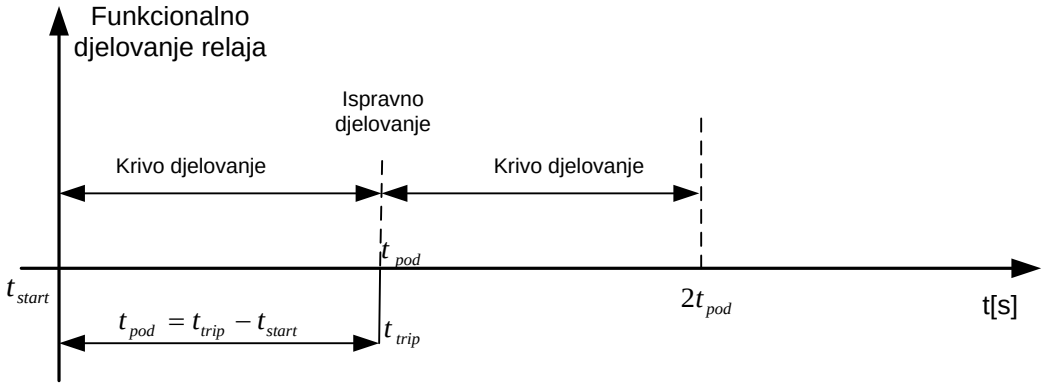
Kako bi releji (nadstrujni, kratkospojni i zemljospojni) ispravno djelovali moraju se prekoračiti strujni i vremenski limit. To su zapravo parametri na koje je relej podešen (strujni limit i vremensko zatezanje). Svaki od tih releja (nadstrujni, kratkospojni i zemljospojni) ima mjerni, vremenski i izvršni član na kojem se mogu podesit strujni limit i vremensko zatezanje. Funkcioniranje nadstrujnih, kratkospojinih i zemljospojnih releja najlakše se objašnjava pomoću strujno-vremenskih karakteristika. Strujno-vremenske karakteristike se dijela na: vremenski ovisne (inverzne), vremenski neovisne, definitive current i kombinacije već spomenutih. Najčešće se kod releja (nadstrjni, kratkospojni i zemljospojni) pojavljuju vremenski ovisna (inverzna) i vremenski neovisna karakteristika. Na slici 6.1a prikazana je vremenski ovisna (inverzna) karakteristika koja predstavlja funkcioniranje releja na način da se kod povećanja struje vrijeme djelovanja smanjuje. Vremenski neovisnu (engl. definitive time) karakteristiku na slici 6.1b objašnjava način rada releja koji ima isto vrijeme djelovanja bez obzira na veličinu struje. Trenutno djelovanje releja čim se prekorači strujni limit prikazano je na slici 6.1c. Kombiniranu karakteristiku djelovanja releja prikazuje slika 6.1d na kojoj se vrijeme djelovanja smanjuje u odnosu na veličinu struje, a nakon nekog maksimalnog iznosa šalje trenutni signal isključenja (bez vremenskog zatezanja). Detaljnije pogledati u [71].



Slika 6.1: Strujno vremenske karakteristike releja

Funkcionalna stanja releja uzimajući u obzir vremenski neovisnu karakteristiku slika 6.1b možemo prikazati pomoću slike 6.2. Na horizontalnoj osi je vrijeme, a na vertikalnoj osi su funkcionalna djelovanja releja (nadstrujni, kratkospojni i zemljospojni). Promotrimo li idealnu situaciju koju prikazuje slika 6.2 za koju vrijedi, ako je razlika vremena stanja isključenja t_{trip} i vremena stanja aktivacije releja t_{start} jednaka podešenom vremenskom zatezanju t_{pod} (vremenski parametar) onda je riječ o ispravnom djelovanju releja što je i prikazano na slici 6.2 kao crtkana linija (vremenski neovisna karakteristika 6.1b). Sve lijevo i desno od crtkane linije smatra se krivim djelovanjem do $2\,t_{pod}$. Na vremenskoj osi $2\,t_{pod}$ uzeto je kao krajnje vrijeme duplo od podešenja iz razloga što nema smisla čekati djelovanje releja duže od toga vremena iz dva razloga, a to su: relej je otkazao i neće uopće djelovati i tu zonu štiti još releja koji mogu pokriti krivi rad i otkazivanje rada tog releja.

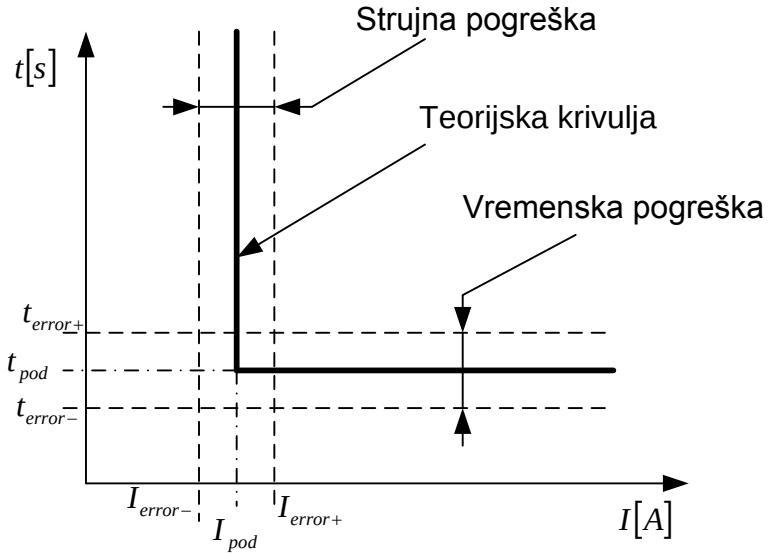
Krivo djelovanje releja se praktički proteže kroz cijelu vremensku os do vremena $2t_{pod}$ isključujući trenutak $t_{trip} = t_{pod}$ u kojem relej ispravno djeluje.



Slika 6.2: Idealna funkcionalna djelovanja releja promatrana u vremenu

Djelovanje releja je u rijetkim slučajevima točno u podešeno vrijeme zatezanja t_{pod} slika 6.3. Svi mjerni uređaji uključujući releje i SMT-e imaju određenu pogrešku prilikom mjerenja koja može biti pozitivna ili negativna [190, 191, 192, 193, 194].

Kod SMT postoji pogreška prijenosnog omjera i fazna pogreška koju uzrokuje struja magnetiziranja. Posljedica pogrešaka SMT-a je to što struja sekundara nije skalirana replika primarne struje što dovodi do vremenske pogreške releja.



Slika 6.3: Vremenska pogreška releja

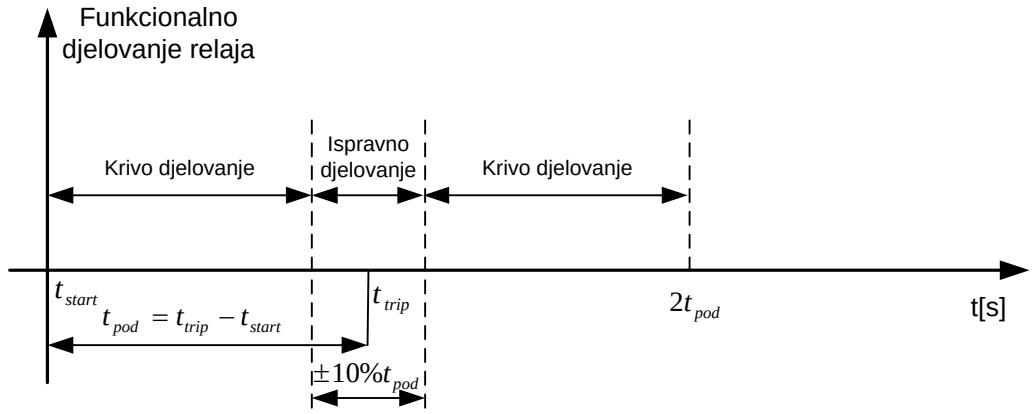
Strujna pogreška koja se javlja prilikom mjerenja (SMT i releja) utječe na vrijeme djelovanja releja te uzrokuje vremensku pogrešku releja (engl. relay timing error) [190, 191, 192, 193, 194] slika 6.3.

Ukupna vremenska pogreška t_{error} je jednaka zbroju vremenske pogreške koju uzrokuje SMT t_{SMT} i vremenske pogreške releja t_R koja se sastoji od vremenske pogreške mjernog člana $t_{R_{mj}}$ i vremenske pogreške vremenskog člana $t_{R_{vr}}$ relacija (6.1) [190, 191, 192, 193, 194].

$$t_{error} = t_{SMT} + \underbrace{t_{R_{mj}} + t_{R_{vr}}}_{t_R} \tag{6.1}$$

Vremenska pogreška releja t_R najviše ovisi o korištenoj tehnologiji [194].

Za ispravno djelovanje releja mora se dozvoliti određena tolerancija vremena impulsa za isključenje t_{trip} koje se nalazi unutar ± 10 % t_{pod} u području ispravnog djelovanja slika 6.4. Definiranjem područja ispravnog djelovanja smanjilo se područje krivog djelovanja slika 6.4. Vrijeme signala isključenja t_{trip} kod ispravnog djelovanja releja nalazi se u vremenskoj zoni ispravnog djelovanja prikazanog na slici 6.4.



Slika 6.4: Realno ispravno djelovanje releja promatrano u vremenu

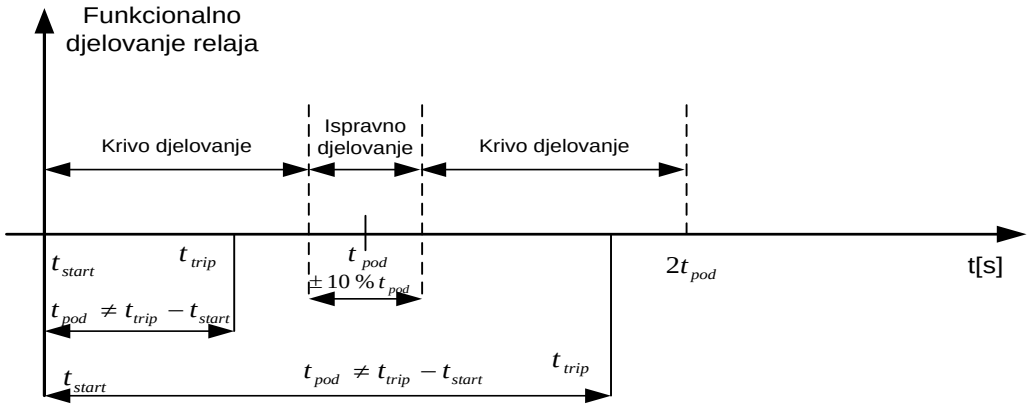
Kod krivog djelovanja releja značajno je to što relej djeluje, ali ne u skladu sa svojim podešenjem vremena slika 6.5. Najčešći uzroci krivog djelovanja releja su: krivo podešeni parametri, neispravnost SMT, neispravnost mjernog člana releja, neispravnost vremenskog člana releja i kombinacije.

Na slici 6.5 su prikazane dvije mogućnosti, a to su:

1) Kada je vrijeme impulsa za isključenje t_{trip} releja vremenski prije podešenog vremena t_{pod} u lijevoj zoni krivog djelovanja i

2) Kada je vrijeme impulsa za isključenje t_{trip} releja događa nakon podešenog vremena (desna zona krivog djelovanja).

Oba slučaja su prikazana na slici 6.5. Postoji samo jedna uska zona u kojoj je riječ o ispravnom djelovanju, a sve izvan toga krivo djelovanje.



Slika 6.5: Krivo djelovanje releja promatrano u vremenu

6.1.1. Ispravna funkcionalna stanja releja i pripadajućeg prekidača prikazano pomoću klasičnog i neizrazitog skupa

Jednopolna shema dalekovodnog polja s funkcionalnom stanjima prikazana je na slici 6.6. Dalekovodno polje se sastoji od rastavljača, prekidača, SMT i releja slika 6.6. Relej se funkcionalno sastoji od mjernog vremenskog i izvršnog člana. Parametri nadstrujnog releja su (I = 300 A, t = 1,5 s) slika 6.6. Mjerni član prati struju kvara te dok struja kvara ne prelazi limit od 300 A ništa se ne događa. U trenutku nastupanja kvara mjerni član detektira kako je prekoračen limit od 300 A slika 6.6a. Prekoračenjem strujnog limita od 300 A pokreće se vremenski član koji odbrojava vrijeme (t = 1,5 s), a relej je u aktivnom stanju koje je prikazano pomoću klasičnog skupa na slici 6.6b. Istovremeno se na KRD-u pojavljuje alarm „nadstrujni relej START i vrijeme t_{start}“. Nakon isteka vremena od t = 1,5 s vremenski član pokreće izvršni član koji šalje impuls za isključenje prekidača (releje u stanju isključenja), a istovremeno se na KRD-u pojavljuje alarm „nadstrujni relej TRIP i vrijeme t_{trip}“. Stanje

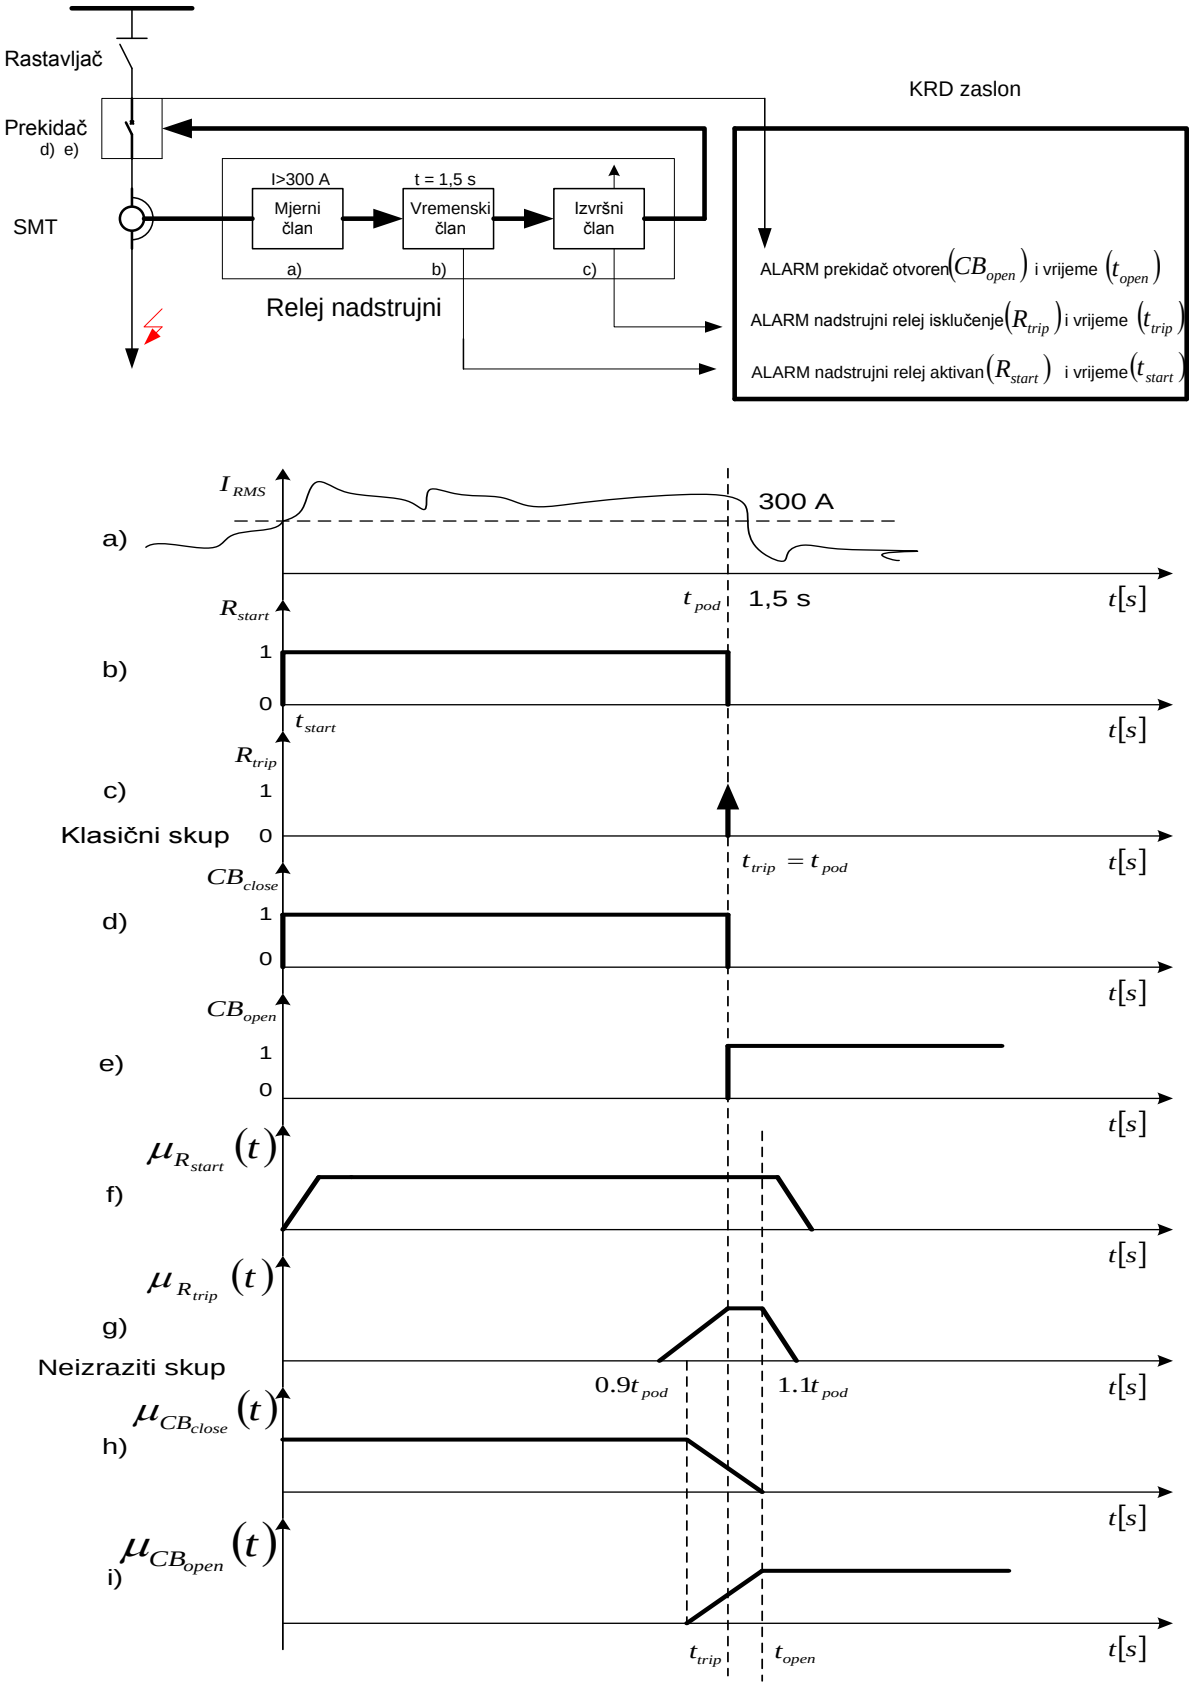
isključenja releja (R_{trip}) prikazano je pomoću klasičnog skupa na slici 6.6c. Nakon slanja impulsa za isključenje (R_{trip}) prekidač isključuje tj. prelazi iz zatvorenog stanja slika 6.6d u otvoreno stanje slika 6.6e, a na KRD-u se pojavljuje alaram „prekidač otvoren i vrijeme t_{open} “. Alarm je skup informacija koji sadrži stanje komponente (relej ili prekidač), naziv komponente (relej ili prekidač), lokaciju komponente (relej ili prekidač) i vrijeme kada je određena komponenta prešla u to stanje $\left(Alarm = \{s\tan je,\ \ naziv,\ \ lokacija,\ \ vrijeme\}\right)$. Stanje, naziv i lokacija su informacije simboličkog (lingvističkog) tipa, a vrijeme je informacija numeričkog tipa.

Stanja na slikama 6.6b-6.6e odgovaraju oznakama stanja koja se nalazi na pripadajućim alarmima kao diskretna informacija. Idealano ispravno djelovanje nadstrujnog releja i pripadajućeg prekidača prikazano je na slikama 6.6b-6.6e pomoću klasičnog skupa. Realni prikaz istih tih stanja pomoću neizrazitog skupa je na slikama 6.6f-6.6i. Aktivno stanje releja prikazano je pomoću funkcije pripadnosti aktivnom stanju releja $\mu_{R_{start}}(t)$ u obliku trapeza slika 6.6f. Za promjenu iz stanja mirovanja u aktivno stanje releja potrebno je određeno vrijeme zbog unutarnje konstrukcije (relej se aktivira između 105-130% podešene struje, a definitivno mora pri 130% podešene struje [190, 191, 192, 193, 194]) što je prikazano lijevom stranicom trapeza kao linearna promjena stanja u vremenu. Nakon toga funkcija pripadnosti aktivnom stanju releja $\mu_{R_{start}}(t)$ postaje konstantna što traje i nakon isteka vremena isključenja od 1.54 s (aktivno stanje traje još malo duže dok se pohranjena energija ne potroši; engl. overshot), a poslije počinje linearno opadati (relej mora napustit aktivno stanje najkasnije pri 70% podešene struje [190, 191, 192, 193, 194]) desna stranica trapeza. Stanje isključenja modelirano je funkcijom pripadnosti stanju isključenja releja $\mu_{R_{trip}}(t)$ u obliku trapeza koji se nalazi u granicama ($\pm 10\% \cdot t_{pod}$), jer se rijetko izvršni član aktivira u idealnih t_{pod} = 1,5 s nego malo prije ili malo poslije toga vremena. Realno stanje isključenja ima svoje određeno vrijeme trajanja (cca. 40ms), što je prikazano gornjom osnovicom trapeza gdje je pripadnost stanju isključenja jednaka jedan ($\mu_{R_{trip}}(t)$=1). Nakon toga funkcija pripadnosti sanju isključenja $\mu_{R_{trip}}(t)$ počima opadati, jer je moguće djelovanje releja i nakon toga vremena sve do $1.1\,t_{pod}$ slika 6.6g.

Nakon što je relej došao u stanje isključenja prekidač isključuje (otvara) dalekovod tj. prekidač prelazi iz zatvorenog stanja u otvoreno stanje. Funkcija pripadnosti otvorenom stanju

prekidača $\mu_{CB_{open}}(t)$ prikazana je pomoću kosog pravca i konstante slika 6.6i. Prekidač zbog svog mehanizma ima određenu tromost reakcije te mu je potrebno određeno vrijeme kako bi prešao iz zatvorenog stanja u otvoreno ($t_{djelovanja}$ = 20ms-80ms), a u modelu je implementirano

$t_{djelovanja} = 40ms$. Ukupno vrijeme otvaranja prekidača t_{open} jednako je zbroju vremena stanja isključenja t_{trip} i vremena djelovanja prekidača $t_{djelovanja}$ $\left(t_{open} = t_{trip} + t_{djelovanja}\right)$. Kosi nagib funkcije pripdanosti otvorenom stanju prekidača $\mu_{CB_{open}}(t)$ prati lijevu stranicu funkcije pripadnosti stanju isključenja releja $\mu_{R_{trip}}(t)$, ali s kašnjenjem od 40 ms. U trenutku t_{open} funkcija pripadnosti otvorenom stanju prekidača jednaka je jedan ($\mu_{CB_{open}}(t)=1$) što označava kako su kontakti prekidača otvoreni, a struja kvara prekinuta. Funkcija pripadnosti zatvorenom stanju prekidača $\mu_{CB_{close}}(t)$ prikazana je pomoću konstante i kosog pravca. Konstantni dio funkcije pripadnosti traje sve do trenutka $0.9\,t_{pod} + 40ms$, a nakon toga kosi pravac označava smanjivanje pripadnosti tom stanju koje traje sve do t_{open} gdje je iznos funkcije pripadnosti zatvorenom stanju prekidača jednaka nuli ($\mu_{CB_{close}}(t)$ = 0) slika 6.6h.



Slika 6.6: Usporedni prikaz stanja releja i prekidača pomoću klasičnog i neizrazitog skupa kod ispravnog djelovanja nadstrujnog releja i prekidača

6.1.2 Funkcionalno djelovanje releja

Releji su uređaji koji štite pojedine komponente i dionice u EES-u. Funkcionalno djelovanje releja opisuje se pomoću: ispravnog djelovanja, krivog djelovanja i otkazivanja djelovanja. Relacije (6.2-6.3) predstavljaju funkcionalan opis tih djelovanja na bazi uzročno posljedične veze kvara i pripadajućeg releja te se nazivaju logičkim jednadžbama funkcioniranja (djelovanja) [27, 60]. Iz tih jednadžbi se ne vidi uzročno posljedična veza koja povezuje aktivno stanje releja R_{start} i stanje isključenja R_{start} nego samo kažu ako imamo ta dva stanja djelovanje je jednako lijevoj strani jednadžbe. Logičke jednadžbe (6.2-6.3) izvedene su po uzoru na [27, 60]. Lijeva strana jednadžbe predstavlja djelovanje releja, a desna kombinaciju dva stanja (alarma). Logičke jednadžbe (6.2-6.3) predstavljaju Booleovu logiku (0 ili 1 tj. crno-bijelo se gleda na model). Ako usporedimo logičke jednadžbe (6.2) i (6.3) vidimo kako je riječ o dva krajnja djelovanja, a to su ispravno djelovanje i otkazivanje djelovanja. Kao što je poznato pomoću Booleove logike nije moguće definirati neko međudjelovanje. Relacija (6.3) predstavlja otkazivanje djelovanja releja te s desne strane ima nepostojeće stanje isključenja NoR_{trip} koje predstavlja nepostojeću informaciju.

$$\mathrm{R}_{operate} = R_{start} * R_{trip} = R_{start} \wedge R_{trip} \tag{6.2}$$

$$\mathrm{R}_{failure_to_operate} = R_{start} * NoR_{trip} = R_{start} \wedge NoR_{trip} \tag{6.3}$$

Međudjelovanje se definira (a to je krivo djelovanje releja) uvođenjem vremena kao dodatnog uvjeta. Početne relacije funkcionalnih djelovanja releja (6.2-6.3) prelaze u relacije (6.4-6.6) s vremenskim uvjetom.

$$\mathrm{R}_{operate} = R_{start} * R_{trip} = R_{start} \wedge R_{trip}, \; t_{trip} - t_{start} = t_{pod} \tag{6.4}$$

$$\mathrm{R}_{fals_operation} = R_{start} * R_{trip} = R_{start} \wedge R_{trip}, \; t_{trip} - t_{start} \neq t_{pod} \tag{6.5}$$

$$\mathrm{R}_{failure_to_operate} = R_{start} * NoR_{trip} \tag{6.6}$$

Usporedimo li relaciju (6.4) i relaciju (6.5) vidimo kao je riječ o istim alarmima (stanjima releja), a razlika je u vremenskom uvjetu. Razlika između vremena stanja isključenja t_{trip} i vremena aktivnog stanja t_{start} kod ispravnog djelovanja jednaka je podešenom vremenu releja

t_{pod} , a kod krivog djelovanja releja je različita. Relacija (6.3) u odnosu na relaciju (6.6) je nepromijenjena.

- Novi način modeliranja funkcionalnih djelovanja releja (ispravno djelovanje, krivo djelovanje i otkazivanje djelovanja) pomoću neizrazite logike u vremenskoj domeni.

$$\mu_{R_operate}(t) = \mu_{R_{start}}(t) \cap \mu_{R_{trip}}(t), \quad t \in \langle 0.9t_{pod}, \quad 1.1t_{pod} \rangle \tag{6.7}$$

$$\mu_{R_false_operation}(t) = \mu_{R_{start}}(t) \cap \mu_{R_{trip}}(t), \quad t \in \lfloor t_{start}, \quad t_{pod}) \cup (t_{pod}, \quad 2t_{pod} \rfloor \tag{6.8}$$

$$\mu_{R_failure_to_operate}(t) = \mu_{R_{start}}(t) \cap \mu_{NoR_{trip}}(t), \quad t \in [t_{start}, \quad t_1) \tag{6.9}$$

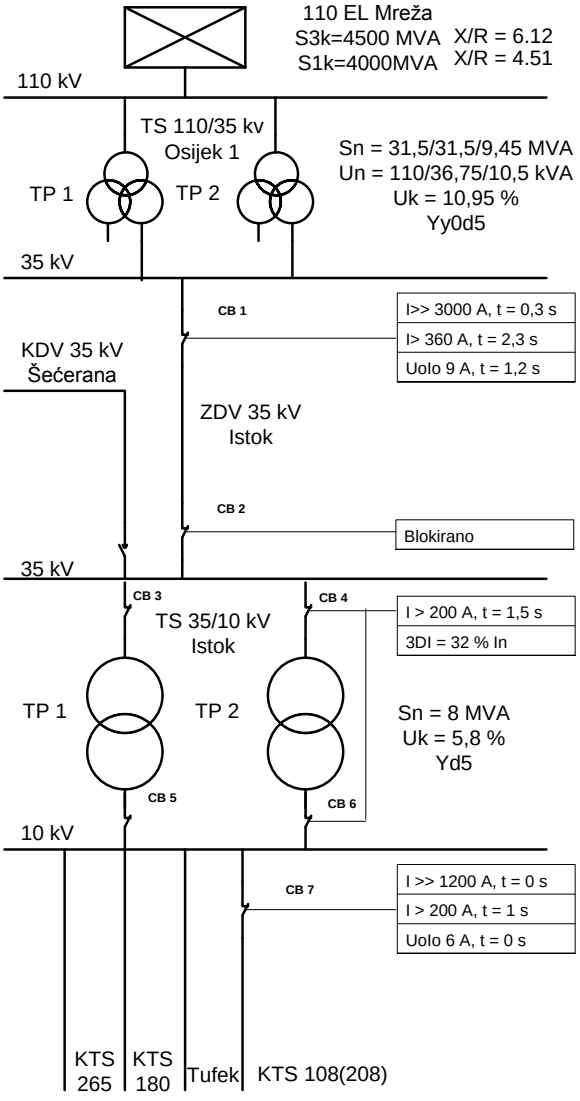
Ispravno djelovanje releja definirano je funkcijom pripadnosti $\mu_{R_operate}(t)$ koje je jednako presjeku funkcije pripadnosti aktivnom stanju $\mu_{R_{start}}(t)$ i funkcije pripadnosti stanju isključenja $\mu_{R_{trip}}(t)$ u vremenskom intervalu $\pm 10\%$ od vremenskog parametra releja t_{pod} (6.7).

Krivo djelovanje releja definirano je funkcijom pripadnosti $\mu_{R_false_operation}(t)$ koje je jednako presjeku funkcije pripadnosti aktivnog stanja releja $\mu_{R_{start}}(t)$ i funkcije pripadnosti stanju isključenja $\mu_{R_{trip}}(t)$ u vremenskom intervalu od vremena aktivnog stanja t_{start} do dvostrukog vremenskog parametra releja $2t_{pod}$ isključujući trenutak t_{pod} u kojem stanje isključenja ima funkciju pripadnosti jednaku jedan (6.8).

Funkcija pripadnosti koja opisuje otkazivanje djelovanje releja $\mu_{R_failure_to_operate}(t)$ jednaka je presjeku funkcije pripadnosti aktivnom stanju releja $\mu_{R_{start}}(t)$ i funkcije pripadnosti nepostojećeg stanja isključenja $\mu_{NoR_{trip}}(t)$ u vremenskom intervalu od početka vremena aktivnog stanja releja t_{start} do vremena t_1 koje je veće od dvostrukog vremenskog parametra releja $2t_{pod}$ u kojem se može očekivati krivi rad releja (6.9).

6.1.3. Model distributivne mreže

Distribucijska (distributivna) mreža koja će se koristiti kao model prikazana je na slici 6.7 (dio 35 kV i 10 kV mreže Elektroslavonije). Mreža se sastoji od dvaju sabirnica 35 kV koje su međusobno povezane s 35 kV dalekovodom, dva transforamtora 35/10 kV, sabirnica 10 kV i četiri dalekovoda 10 kV. Dalekovod 35 kV štiti nadstrujni, kratkospojini i zemljospojni relej. Transformatore 35/10 kV štiti nadstrujni i diferencijalni relej, a dalekovode 10 kV štiti nadstrujni, kratkospojni i zemljospojni relej.

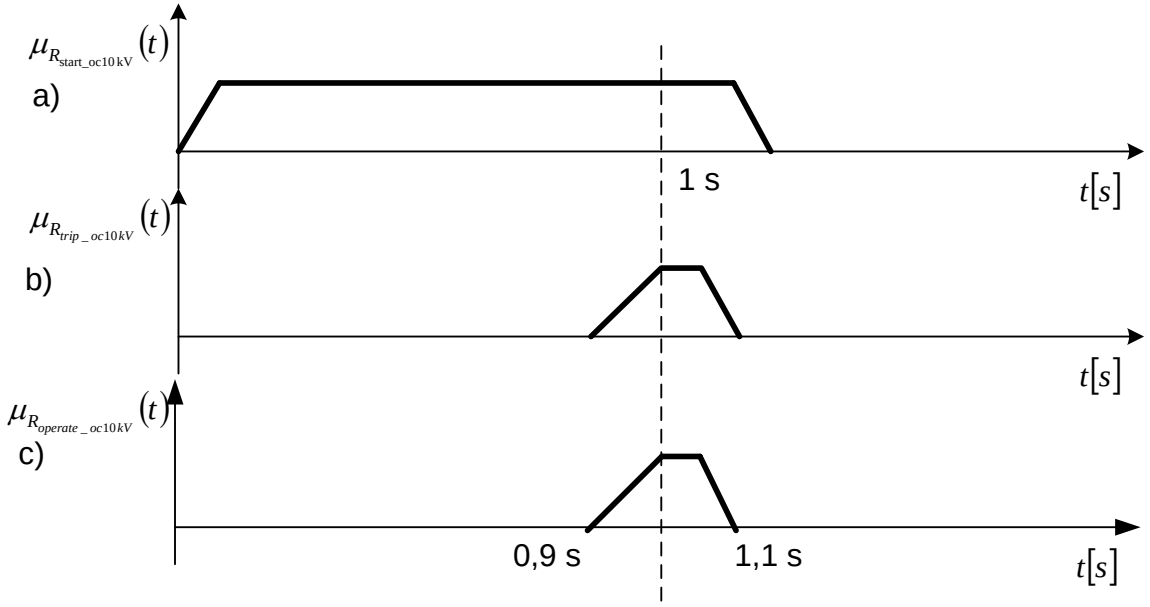


Slika 6.7: Dio 35 kV mreže Elektroslavonije

6.2. Dalekovod 10 kV

6.2.1. Ispravno djelovanje nadstrujnog releja koji štiti dalekovod 10 kV

Ispravno djelovanje releja definirano je relacijom (6.7). Funkcioniranje nadstrujnog releja na vodnom polju 10 kV prikazano je pomoću funkcije pripadnosti aktivnom stanju releja $\mu_{R_{start_oc10kV}}(t)$ slika 6.8a i funkcije pripadnosti stanju isključenja slika 6.8b. Na slici 6.8c je prikazana funkcija pripadnosti ispravnog djelovanja nadstrujnog releja $\mu_{R_{operate_oc10kV}}(t)$ koja je dobivena kao presjek funkcija pripadnosti sa slike 6.8(a i b). Funkcija pripadnosti ispravnog djelovanja nadstrujnog releja prikazana je i relacijom (6.10).

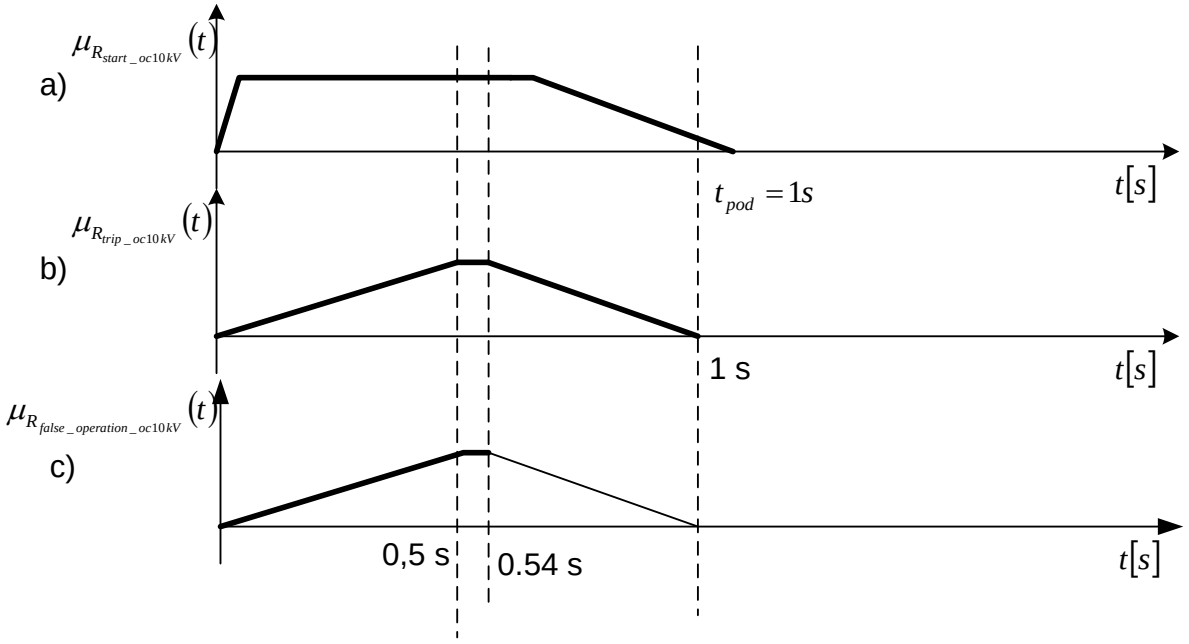


Slika 6.8: Funkcije pripadnosti u odnosu ispravnog djelovanja nadstrujnog releja

$$\mu_{R_{operate_oc10kV}}(t) = \mu_{R_{start_oc10kV}}(t) \cap \mu_{R_{trip_oc10kV}}(t) = \begin{cases} 10t - 9 & t \in \langle 0.9 \quad 1 \rangle \\ 1 & t \in \langle 1 \quad 1.04 \rangle \\ -16.67t + 18.34 & t \in \langle 1.04 \quad 1.1 \rangle \end{cases} \tag{6.10}$$

6.2.2. Krivo djelovanje nadstrujnog releja koji štiti dalekovod 10 kV

Krivo djelovanje nadstrujnog releja prikazano je na slici 6.9 te definirano relacijom (6.8). Funkcija pripadnosti aktivnog stanja nadstrujnog releja na dalekovodu 10 kV $\mu_{R_{start_oc10kV}}(t)$ prikazana je na slici 6.9a, a stanje isključenja prilikom krivog djelovanja nadstrujnog releja pomoću funkcije pripadnosti $\mu_{R_{trip_oc10kV}}(t)$ prikazano je na slici 6.9b. Krivo djelovanje nadstrujnog releja na dalekovodu 10 kV $\mu_{R_{fales_operation_oc10kV}}(t)$ prikazano je pomoću funkcije pripadnosti na slici 6.9c i definirano relacijom (6.11), a grafički dobiven pomoću presjeka slika 6.9(a i b).

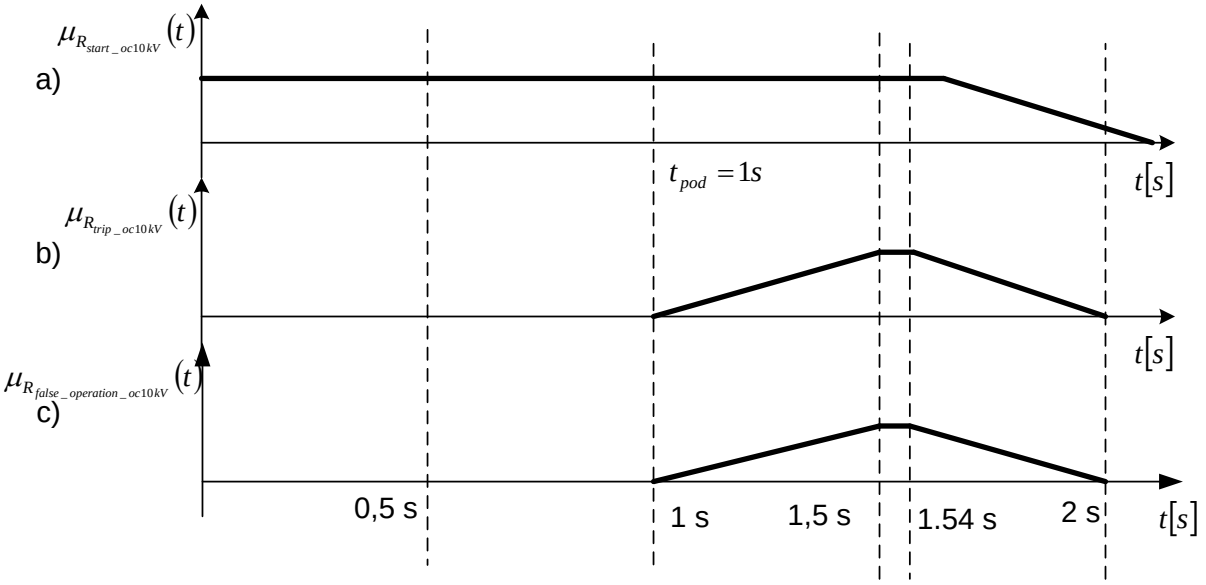


Slika 6.9: Funkcija pripadnosti krivog djelovanja nadstrujnog releja na dalekovodu 10 kV

$$\mu_{R_{false_operation_oc10kV}}(t) = \mu_{R_{start_oc10kV}}(t) \cap \mu_{R_{trip_oc10kV}}(t) = \begin{cases} 2t & t \in \langle 0 \quad 0.5 \rangle \\ 1 & t \in \langle 0.5 \quad 0.54 \rangle \\ -2.17t + 2.17 & t \in \langle 0.54 \quad 1 \rangle \end{cases} \tag{6.11}$$

Krivo djelovanje nadstrujnog releja koji štiti dalekovod 10 kV moguće je i nakon podešenog vremena od t_{pod} = 1 s što je prikazano na slici 6.10, a definirano relacijom (6.8). Funkcija pripadnosti krivog djelovanja nadstrujnog releja na dalekovodu 10 kV $\mu_{R_{false_operation_oc10kV}}(t)$ prikazana je na slici 6.10c, a dobivena je i iskazana pomoću relacije (6.12) kao presjek

funkcije pripadnosti aktivnog stanja nadstrujnog releja na dalekovodu 10 kV $\mu_{R_{start_oc10kV}}(t)$ slika 6.10a i funkcije pripadnosti stanja isključenja nadstrujnog releja na dalekovodu 10 kV $\mu_{R_{trip_oc10kV}}(t)$ slika 6.10b.



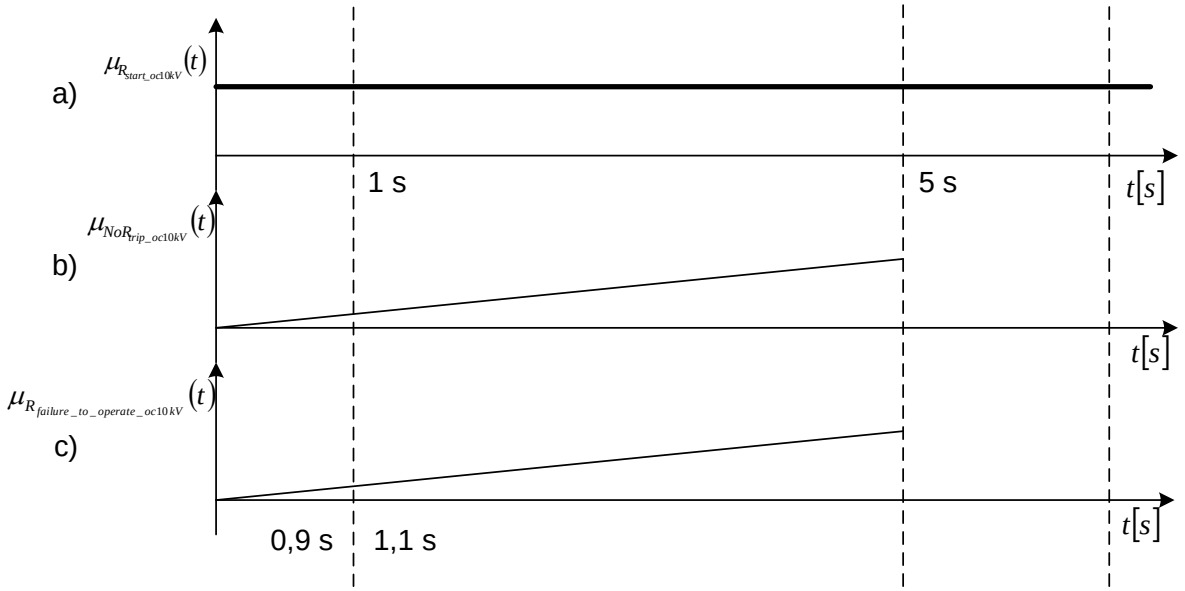
Slika 6.10: Funkcija pripadnosti krivog djelovanja nadstrujnog releja koji štiti dalekovod 10 Kv

$$\mu_{R_{false_operation_oc10kV}}(t) = \mu_{R_{start_oc10kV}}(t) \cap \mu_{R_{trip_oc10kV}}(t) = \begin{cases} 2t-2 & t \in \langle 1 \quad 1.5 \rangle \\ 1 & t \in \langle 1.5 \quad 1.54 \rangle \\ -2.17t + 4.34 & t \in \langle 1.54 \quad 2 \rangle \end{cases} \tag{6.12}$$

6.2.3. Otkazivanje djelovanja nastrujnog releja koji štiti dalekovod 10 kV

Otkazivanje nadstrujnog releja na dalekovodu 10 kV definirano je relacijom (6.9) te prikazano na slici 6.11. Funkcija pripadnosti otkazivanja djelovanja nadstrujnog releja na dalekovodu 10 kV $\mu_{R_{failure_to_operate_oc10kV}}(t)$ prikazana je na slici 6.11c, a dobivena je i iskazana pomoću relacije (6.13) kao presjek funkcije pripadnosti aktivnom stanju nadstrujnog releja

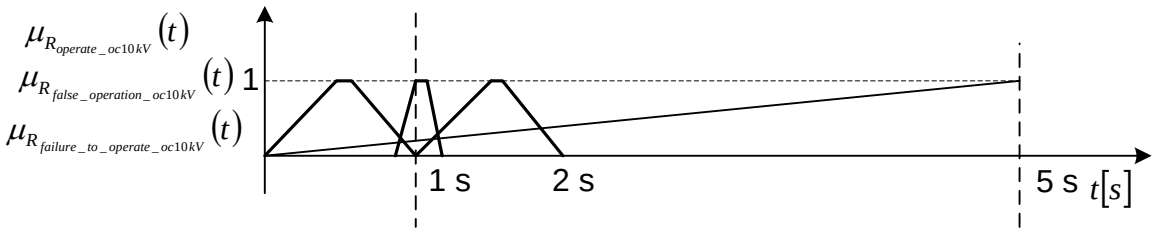
koji štiti dalekovod 10 kV $\mu_{R_{start_oc10kV}}(t)$ slika 6.11a i funkcije pripadnosti nepostojećeg stanja isključenje nadstrujnog releja koji štiti dalekovod 10 kV $\mu_{NoR_{trip_oc10kV}}(t)$ slika 6.11b.



Slika 6.11: Funkcija pripadnosti otkazivanja djelovanja nadstrujnog releja koji štiti dalekovod 10 kV

$$\mu_{R_{failure_to_operate_oc10kV}}(t) = \mu_{R_{start_oc10kV}}(t) \cap \mu_{NoR_{trip_oc10kV}}(t) = 0.2t, \quad t \in \langle 0 \quad 5 \rangle \tag{6.13}$$

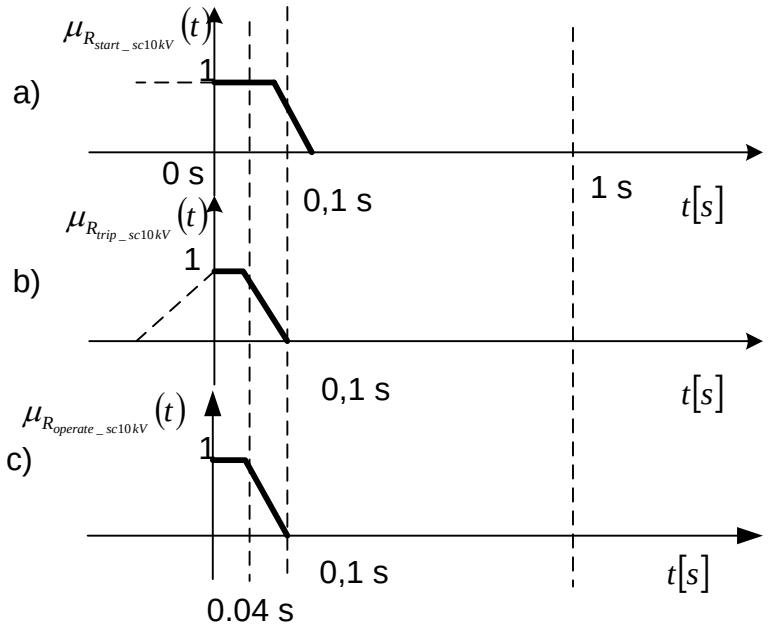
Skupni prikaz funkcija pripadnosti, djelovanja, krivog djelovanja i otkazivanja djelovanja nadstrujnog releja na dalekovodu 10 kV slika 6.12.



Slika 6.12: Funkcije pripadnosti djelovanja, krivog djelovanja i otkazivanja djelovanja nadstrujnog releja koji štiti dalekovodu 10 kV

6.2.4. Ispravno djelovanje kratkospojnog releja koji štiti dalekovod 10 kV

Ispravno djelovanje kratkospojnog releja koji štiti dalekovod 10 kV prikazano je pomoću funkcije pripadnosti $\mu_{R_{operate_sc10kV}}(t)$ na slici 6.13c, a dobiveno pomoću relacije 6.14 te iskazano kao presjek funkcije pripadnosti aktivnom stanju kratkospojnog releja $\mu_{R_{start_sc10kV}}(t)$ slika 6.13a i funkcije pripadnosti stanju isključenja $\mu_{R_{trip_sc10kV}}(t)$ slika 6.13b.

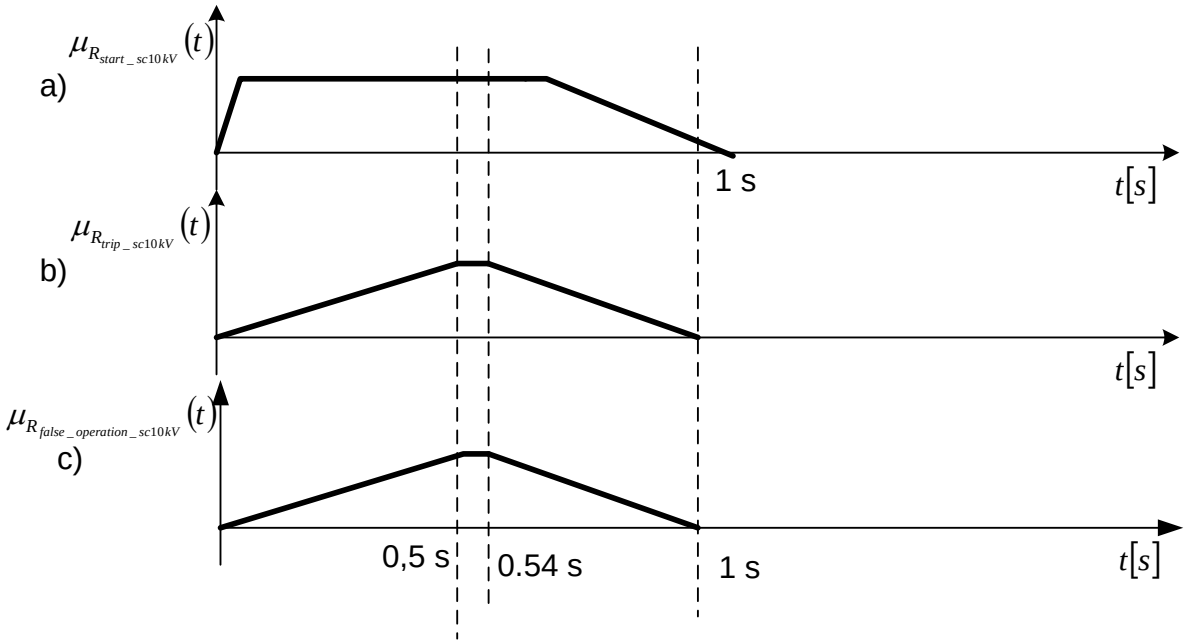


Slika 6.13: Funkcija pripadnosti ispravnog djelovanja kratkospojnog releja koji štiti dalekovod 10 kV

$$\mu_{R_{operate_sc10kV}}(t) = \mu_{R_{start_sc10kV}}(t) \cap \mu_{R_{trip_sc10kV}}(t) = \begin{cases} 1 & t \in \langle 0 \quad 0.04 \rangle \\ -16.64t + 1.67 & t \in \langle 0.04 \quad 0.1 \rangle \end{cases} \tag{6.14}$$

6.2.5. Krivo djelovanje kratkospojnog releja koji štiti dalekovod 10 kV

Krivo djelovanje kratkospojnog releja koji štiti dalekovod 10 kV prikazano je pomoću funkcije pripadnosti $\mu_{R_{false_operation_sc10kV}}(t)$ koje je prikazano na slici 6.14c, a iskazano pomoću relacije (6.15) kao presjek funkcije pripadnosti aktivnom stanju kratkospojnog releja $\mu_{R_{start_sc10kV}}(t)$ slika 6.14a i funkcije pripadnosti stanja isključenja $\mu_{R_{trip_sc10kV}}(t)$ slika 6.14b.

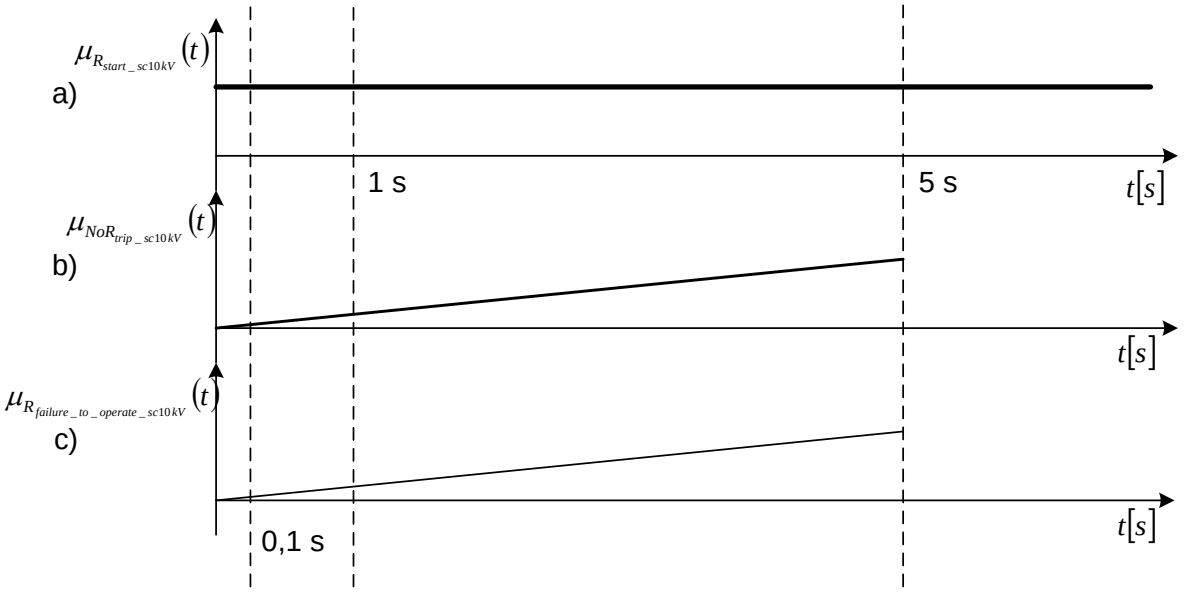


Slika 6.14: Funkcija pripadnosti krivog djelovanja kratkospojnog releja koji štiti dalekovod 10 kV

$$\mu_{R_{false_operation_sc10kV}}(t) = \mu_{R_{start_sc10kV}}(t) \cap \mu_{R_{trip_sc10kV}}(t) = \begin{cases} 2t & t \in \langle 0 \quad 0.5 \rangle \\ 1 & t \in \langle 0.5 \quad 0.54 \rangle \\ -2.17t + 2.17 & t \in \langle 0.54 \quad 1 \rangle \end{cases} \tag{6.15}$$

6.2.6. Otkazivanje djelovanja kratkospojnog releja koji štiti dalekovod 10 kV

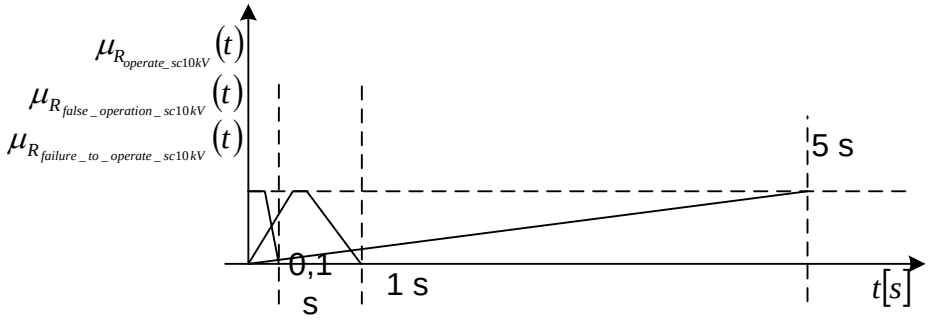
Funkcija pripadnosti otkazivanja djelovanja kratkospojnog releja koji štiti dalekovod 10 kV $\mu_{R_{failure_to_operate_sc10kV}}(t)$ prikazana je na slici 6.15c, a dobivena je pomoću relacije 6.16 kao presjek funkcije pripadnosti aktivnom stanju kratkospojnog releja koji štiti dionicu dalekovoda 10 kV $\mu_{R_{start_sc10kV}}(t)$ slika 6.15a i funkcije pripadnosti nepostojećeg stanja isključenja kratkospojenog releja za koji štiti dionicu dalekovoda 10 kV $\mu_{NoR_{trip_sc10kV}}(t)$ slika 6.15b.



Slika 6.15: Funkcije pripadnosti otkazivanja djelovanja kratkospojnog releja koji štiti dionicu dalekovoda 10 kV

$$\mu_{R_{failure_to_operate_sc10kV}}(t) = \mu_{R_{start_sc10kV}}(t) \cap \mu_{NoR_{trip_sc10kV}}(t) = 0.2t, \quad t \in \langle 0 \quad 5 \rangle \tag{6.16}$$

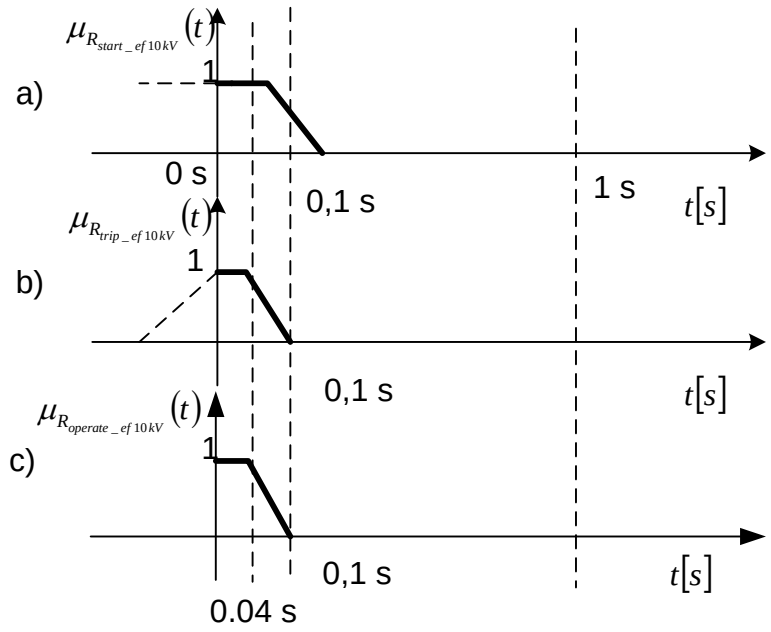
Skupni prikaz funkcija pripadnosti djelovanja, krivog djelovanja i otkazivanja djelovanja kratkospojnog releja koji štiti dalekovod 10 kV slika 6.16.



Slika 6.16: Funkcije pripadnosti ispravnog djelovanja, krivog djelovanja i otkazivanja djelovanja kratkospojnog releja koji štiti dionicu dalekovoda 10 kV

6.2.7. Ispravno djelovanje zemljospojnog releja koji štiti dalekovod 10 kV

Ispravno djelovanje zemljospojnog releja koji štiti dalekovod 10 kV prikazano je pomoću funkcije pripadnosti $\mu_{R_{operate_ef10kV}}(t)$ na slici 6.17c, a dobiveno je pomoću relacije (6.17) iskazane kao presjek funkcije pripadnosti aktivnom stanju zemljospojnog releja koji štiti dionicu dalekovoda 10 kV $\mu_{R_{start_ef10kV}}(t)$ slika 6.17a i funkcije pripadnosti stanju isključenja zemljospojnog releja koji štiti dionicu dalekovoda 10 kV $\mu_{R_{trip_ef10kV}}(t)$ slika 6.17b.



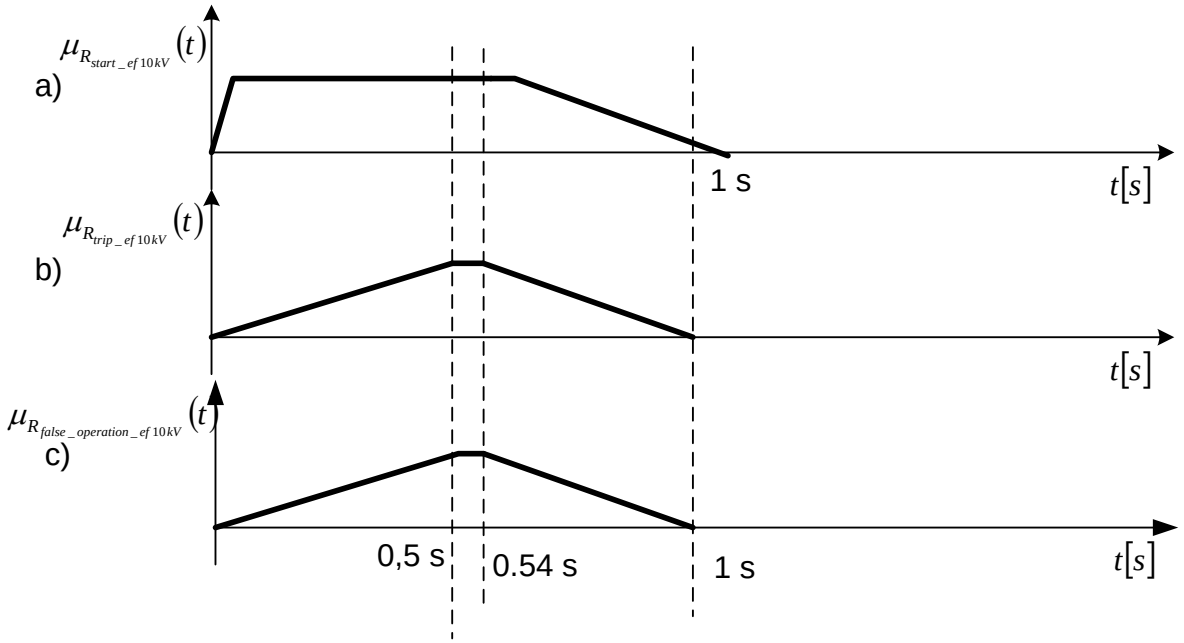
Slika 6.17: Funkcije pripadnosti ispravnog djelovanja zemljospojnog releja koji štiti dionicu dalekovoda 10 kV

$$\mu_{R_{operate_ef10kV}}(t) = \mu_{R_{start_ef10kV}}(t) \cap \mu_{R_{trip_ef10kV}}(t) = \begin{cases} 1 & t \in \langle 0 \quad 0.04 \rangle \\ -16.64t + 1.67 & t \in \langle 0.04 \quad 0.1 \rangle \end{cases} \tag{6.17}$$

6.2.8. Krivo djelovanje zemljospojnog releja koji štiti dalekovod 10 kV

Krivo djelovanje zemljospojnog releja koji štiti dalekovod 10 kV prikazano je pomoću funkcije pripadnosti $\mu_{R_{false_operation_ef10kV}}(t)$ prikazano na slici 6.18c, a iskazano pomoću relacije

(6.18) kao presjek funkcije pripadnosti aktivnom stanju zemljospojnog releja koji štiti dalekovod 10 kV $\mu_{R_{start_ef10kV}}(t)$ slika 6.18a i funkcije pripadnosti stanju isključenja zemljospojnog releja koji štiti dalekovod 10 kV $\mu_{R_{trip_sc10kV}}(t)$ slika 6.18b.



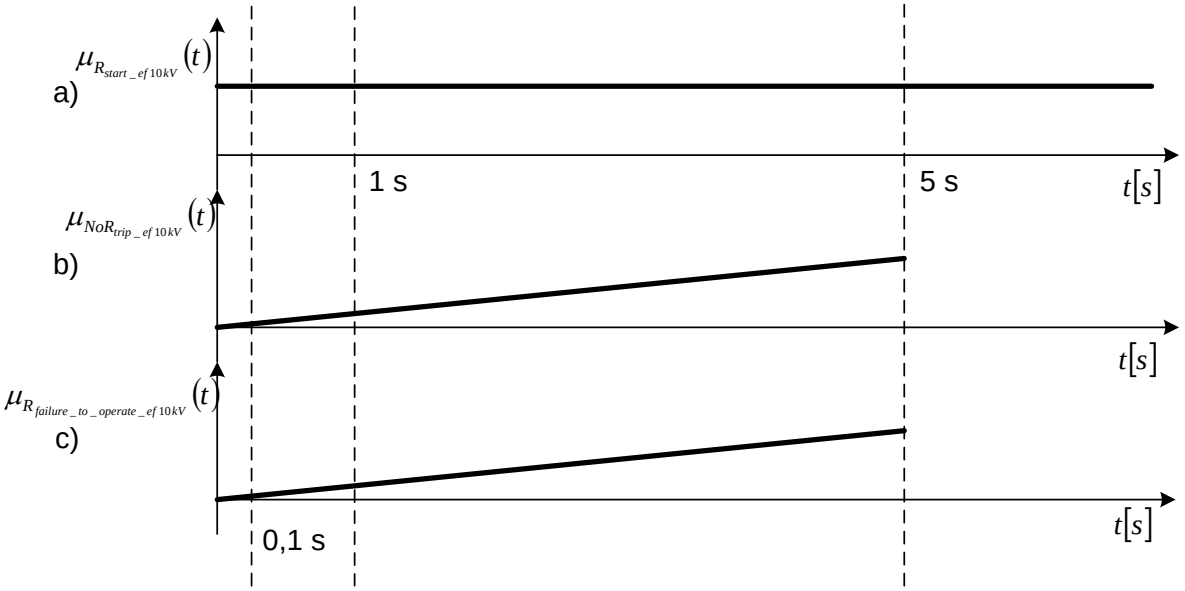
Slika 6.18: Funkcije pripadnosti krivog djelovanja zemljospojnog releja koji štiti dalekovod 10 kV

$$\mu_{R_{false_operation_ef10kV}}(t) = \mu_{R_{start_ef10kV}}(t) \cap \mu_{R_{trip_ef10kV}}(t) = \begin{cases} 2t & t \in \langle 0 \quad 0.5 \rangle \\ 1 & t \in \langle 0.5 \quad 0.54 \rangle \\ -2.17t + 2.17 & t \in \langle 0.54 \quad 1 \rangle \end{cases} \tag{6.18}$$

6.2.9. Otkazivanje djelovanja zemljospojnog releja koji štiti dalekovod 10 kV

Funkcija pripadnosti otkazivanja djelovanja zemljospojnog releja koji štiti dalekovod 10 kV $\mu_{R_{failure_to_operate_ef10kV}}(t)$ prikazana je na slici 6.19c, a dobivena je pomoću relacije (6.19) kao presjek funkcije pripadnosti aktivnog stanja zemljospojnog releja koji štiti dionicu dalekovoda 10 kV $\mu_{R_{start_ef10kV}}(t)$ slika 6.19a i funkcije pripadnosti nepostojećeg stanja

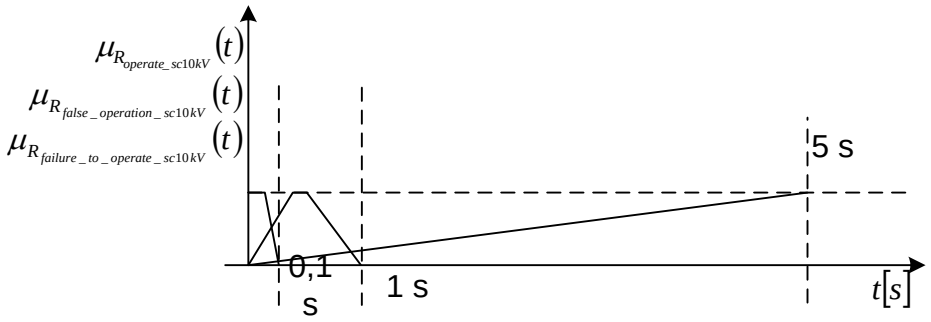
isključenja zemljospojnog releja koji štiti dionicu dalekovoda 10 kV $\mu_{NoR_{trip_ef10kV}}(t)$ slika 6.19b.



Slika 6.19: Funkcije pripadnosti otkazivanja djelovanja zemljospojnog releja koji štiti dalekovod 10 kV

$$\mu_{R_{failure_to_operate_ef10kV}}(t) = \mu_{R_{start_ef10kV}}(t) \cap \mu_{NoR_{trip_ef10kV}}(t) = 0.2t, \quad t \in \langle 0 \quad 5 \rangle \tag{6.19}$$

Zbirni prikaz funkcija pripadnosti ispravnog djelovanja, krivog djelovanja i otkazivanja djelovanja zemljospojnog releja koji štiti dalekovod 10 kV na slici 6.20.

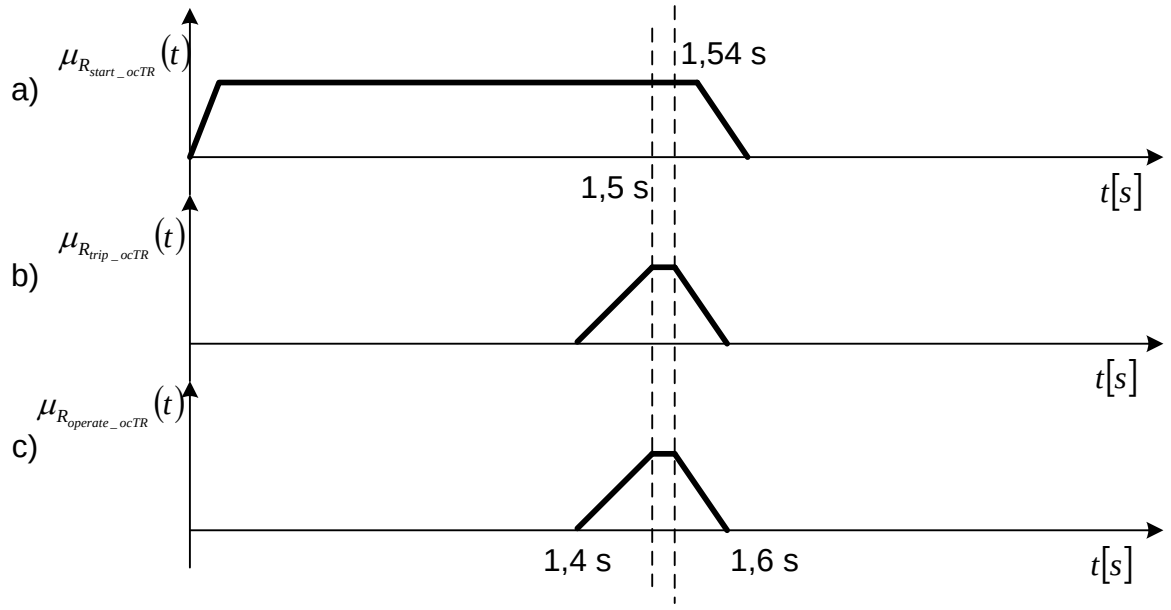


Slika 6.20: Funkcije pripadnosti ispravnog djelovanja, krivog i otkazivanja djelovanja zemljospojnog releja koji štiti dalekovod 10 kV

6.3. Transformator

6.3.1. Ispravno djelovanje nadstrujnog releja koji štiti transformator

Ispravno djelovanje nadstrujnog releja koji štiti transformator prikazano pomoću funkcije pripadnosti $\mu_{R_{operate_ocTR}}(t)$ prikazano je na slici 6.21c, a dobiveno pomoću relacije (6.20) iskazane kao presjek funkcije pripadnosti aktivnog stanja nadstrujnog releja koji štiti transformator $\mu_{R_{start_ocTR}}(t)$ slika 6.21a i funkcije pripadnosti stanju isključenja nadstrujnog releja koji štiti transformator $\mu_{R_{trip_ocTR}}(t)$ slika 6.21b.



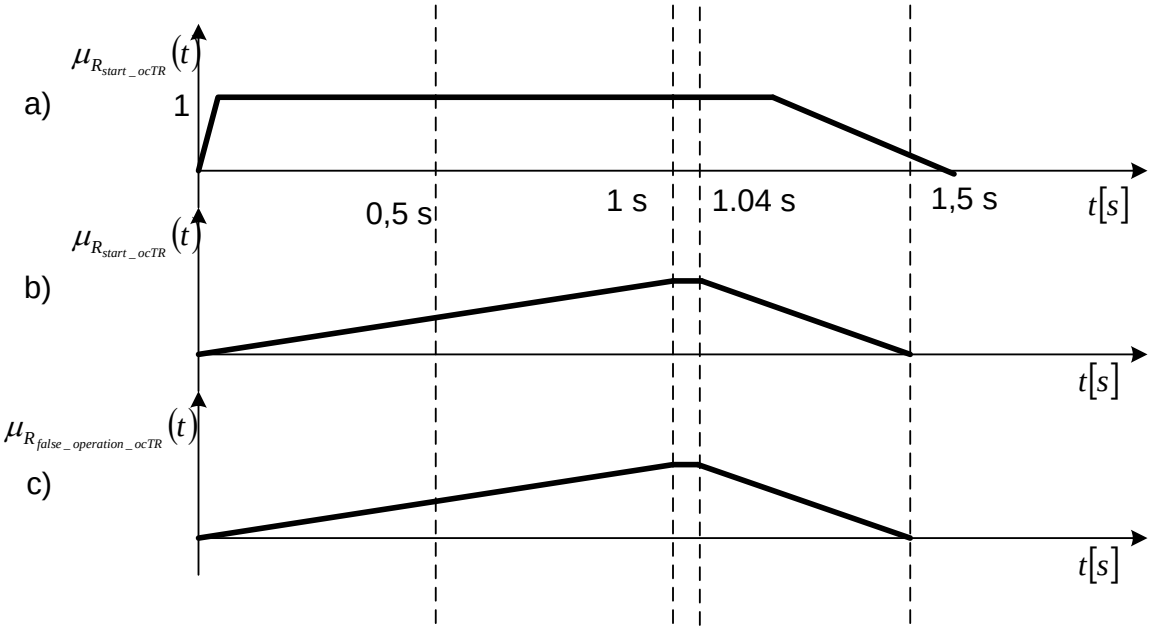
Slika 6.21: Funkcije pripadnosti ispravnog djelovanja nadstrujnog releja koji štiti transformator

$$\mu_{R_{operate_ocTR}}(t) = \mu_{R_{start_ocTR}}(t) \cap \mu_{R_{trip_ocTR}}(t) = \begin{cases} 10t - 14 & t \in \langle 1.4 \quad 1.5 \rangle \\ 1 & t \in \langle 1.5 \quad 1.54 \rangle \\ -16.67t + 26 & t \in \langle 1.54 \quad 1.6 \rangle \end{cases} \tag{6.20}$$

6.3.2. Krivo djelovanje nadstrujnog releja koji štiti transformator

Funkcija pripadnosti aktivnom stanju nadstrujnog releja koji štiti transformator $\mu_{R_{start_ocTR}}(t)$ prikazana je na slici 6.22a, a funkcija pripadnosti stanju isključenja $\mu_{R_{trip_oc10TR}}(t)$ prikazana je na slici 6.22b. Krivo djelovanje nadstrujnog releja koji štiti transformator

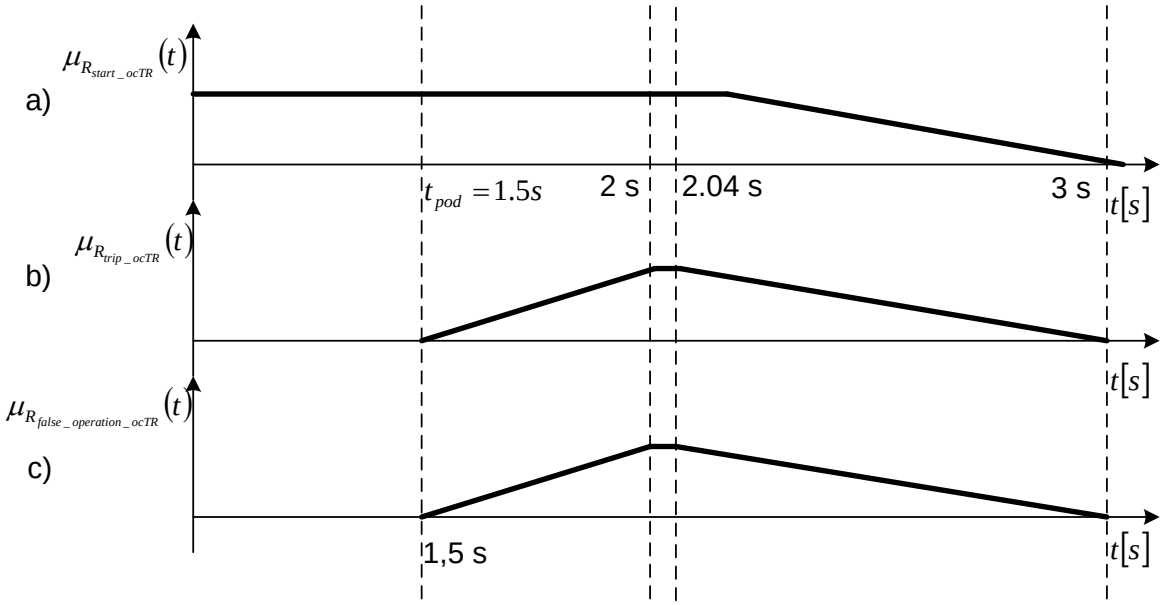
$\mu_{R_{fales_operation_ocTR}}(t)$ prikazano je pomoću funkcije pripadnosti na slici 6.22c i definirano relacijom (6.21), a grafički je dobiveno pomoću presjeka slika 6.22(a i b).



Slika 6.22: Funkcija pripadnosti krivog djelovanja nadstrujnog releja koji štiti transformator

$$\mu_{R_{false_operation_ocTR}}(t) = \mu_{R_{start_ocTR}}(t) \cap \mu_{R_{trip_ocTR}}(t) = \begin{cases} t & t \in \langle 0 \quad 1 \rangle \\ 1 & t \in \langle 1 \quad 1.04 \rangle \\ -2.17t + 3.26 & t \in \langle 1.04 \quad 1.5 \rangle \end{cases} \tag{6.21}$$

Krivo djelovanje nadstrujnog releja koje štiti transformator moguće je i nakon podešenog vremena od t_{pod} = 1.5 s što je prikazano na slici 6.23, a definirano relacijom 6.22. Funkcija pripadnosti krivog djelovanja nadstrujnog releja koji štiti transformator $\mu_{R_{false_operation_ocTR}}(t)$ prikazana je na slici 6.23c, a dobivena je pomoću relacije (6.22) kao presjek funkcije pripadnosti aktivnom stanju nadstrujnog releja koji štiti transformator $\mu_{R_{start_ocTR}}(t)$ slika 6.23a i funkcije pripadnosti stanju isključenja nadstrujnog releja koji štiti transformator $\mu_{R_{trip_ocTR}}(t)$ slika 6.23b.

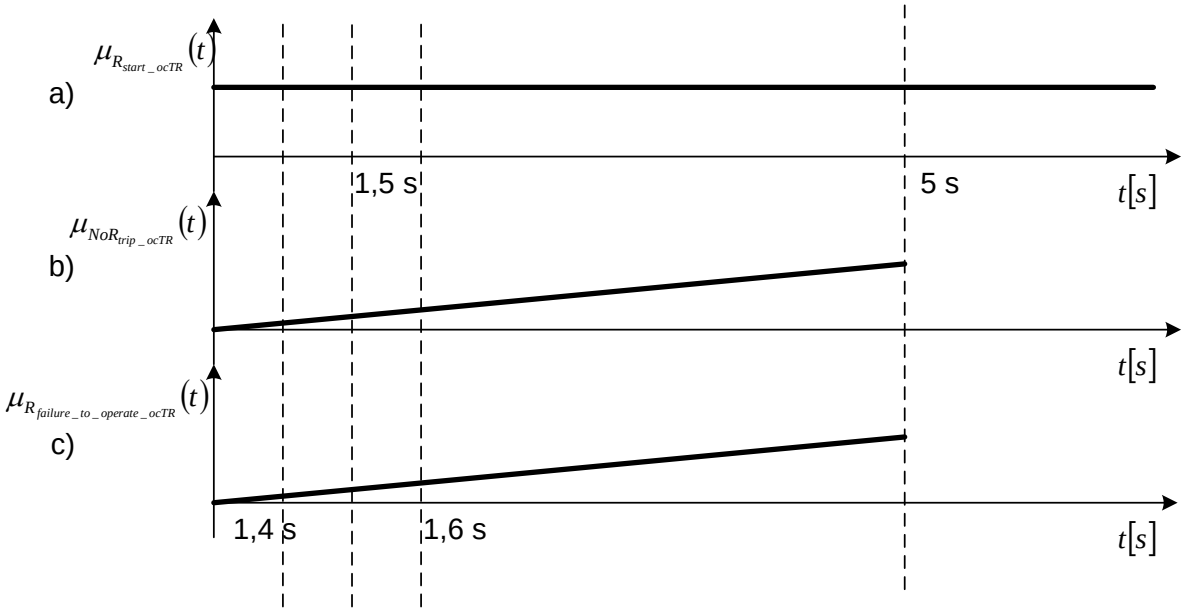


Slika 6.23: Funkcija pripadnosti krivog djelovanja nadstrujnog releja koji štiti transformator

$$\mu_{R_{false_operation_ocTR}}(t) = \mu_{R_{start_ocTR}}(t) \cap \mu_{R_{trip_ocTR}}(t) = \begin{cases} 2t-3 & t \in \langle 1.5 \quad 2 \rangle \\ 1 & t \in \langle 2 \quad 2.04 \rangle \\ -1.04t & t \in \langle 2.04 \quad 3 \rangle \end{cases} \tag{6.22}$$

6.3.3. Otkazivanje djelovanja nadstrujnog releja koji štiti transformator

Funkcija pripadnosti otkazivanja djelovanja nadstrujnog releja koji štiti transformator $\mu_{R_{failure_to_operate_ocTR}}(t)$ prikazana je na slici 6.24c, a dobivena je pomoću relacije (6.23) kao presjek funkcije pripadnosti aktivnog stanja nadstrujnog releja koji štiti transformator $\mu_{R_{start_ocTR}}(t)$ slika 6.24a i funkcije pripadnosti nepostojećeg stanja isključenja nadstrujnog releja koji štiti transformator $\mu_{NoR_{trip_ocTR}}(t)$ slika 6.24b.



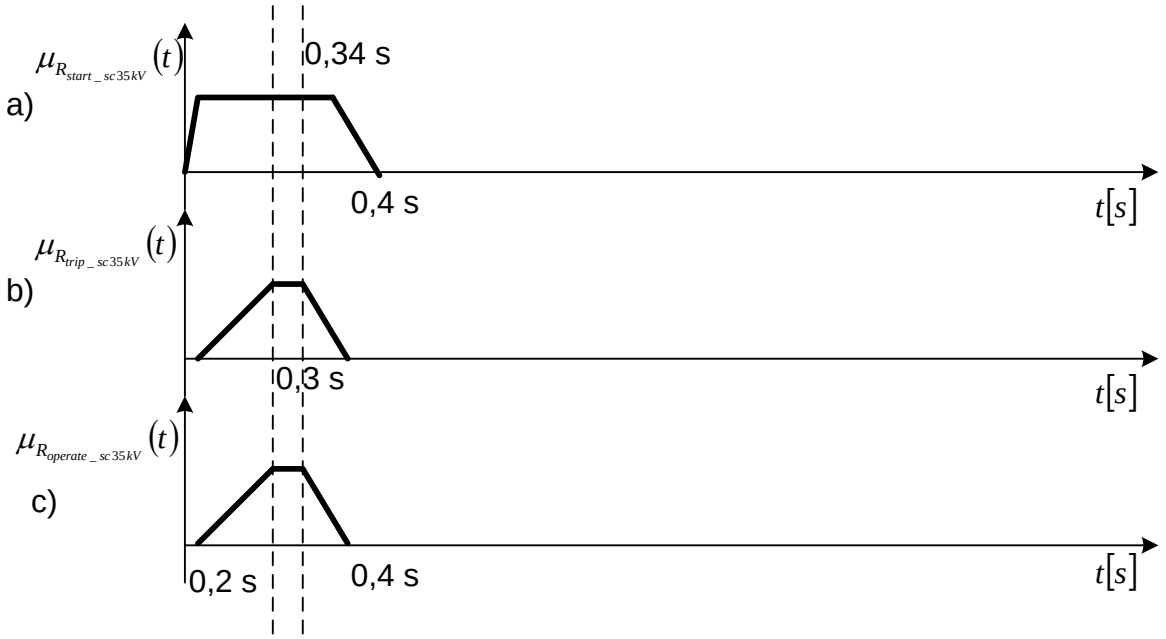
Slika 6.24: Funkcije pripadnosti otkazivanje djelovanja nadstrujnog releja koji štiti transformator

$$\mu_{R_{failure_to_operate_ocTR}}(t) = \mu_{R_{start_ocTR}}(t) \cap \mu_{NoR_{trip_ocTR}}(t) = 0.2t, \quad t \in \langle 0 \quad 5 \rangle \tag{6.23}$$

6.4. Dalekovod 35 kV

6.4.1. Ispravano djelovanje kratkospojnog releja koji štiti dalekovod 35 kV

Funkcija pripadnosti ispravnog djelovanja kratkospojnog releja koji štiti dalekovod 35 kV $\mu_{R_{operate_sc35kV}}(t)$ prikazana je na slici 6.25c, a dobivena je pomoću relacije (6.24) iskazane kao presjek funkcije pripadnosti aktivnom stanju kratkospojnog releja koji štiti dalekovod 35 kV $\mu_{R_{start_sc35kV}}(t)$ slika 6.25a i funkcije pripadnosti stanju isključenja kratkospojnog releja koji štiti dalekovod 35 kV $\mu_{R_{trip_sc35kV}}(t)$ slika 6.25b.

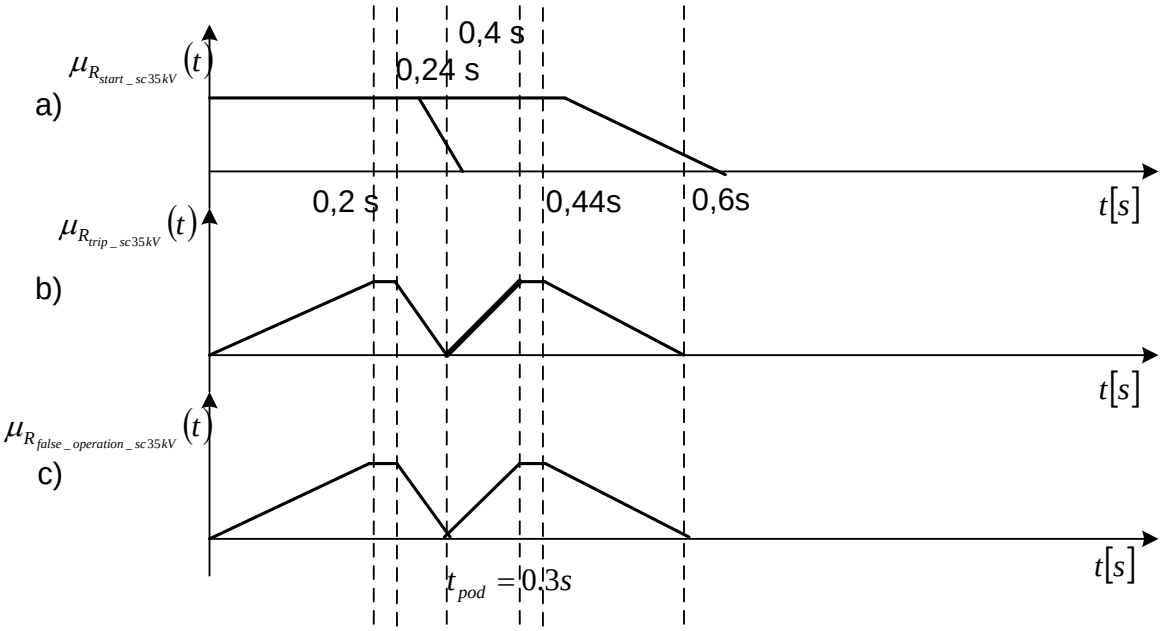


Slika 6.25: Funkcije pripadnosti ispravnog djelovanja kratkospojnog releja koji štiti dalekovod 35 kV

$$\mu_{R_{operate_sc35kV}}(t) = \mu_{R_{start_sc35kV}}(t) \cap \mu_{R_{trip_sc35kV}}(t) = \begin{cases} 10t - 2 & t \in \langle 0.2 \quad 0.3 \rangle \\ 1 & t \in \langle 0.3 \quad 0.34 \rangle \\ -16.67t + 6.67 & t \in \langle 0.34 \quad 0.4 \rangle \end{cases} \tag{6.24}$$

6.4.2. Krivo djelovanje kratkospojnog releja koji štiti dalekovod 35 kV

Funkcije pripadnosti aktivnih stanja kratkospojnog releja prilikom krivog djelovanja koji štiti dalekovod 35 kV $\mu_{R_{start_sc35kV}}(t)$ prikazane su na slici 6.26a, a stanja isključenja prilikom krivog djelovanja kratkospojnog releja pomoću funkcije pripadnosti $\mu_{R_{trip_sc35kV}}(t)$ prikazani su na slici 6.26b za vremenski interval prije $t_{pod} = 0.3s$ i za vremenski interval nakon $t_{pod} = 0.3s$. Krivo djelovanje kratkospojnog releja koji štiti dalekovod 35kV $\mu_{R_{fales_operation_sc35kV}}(t)$ prikazano je pomoću funkcije pripadnosti na slici 6.26c i definirano relacijom (6.25), a grafički je dobiveno pomoću presjeka slika 6.26(a i b).

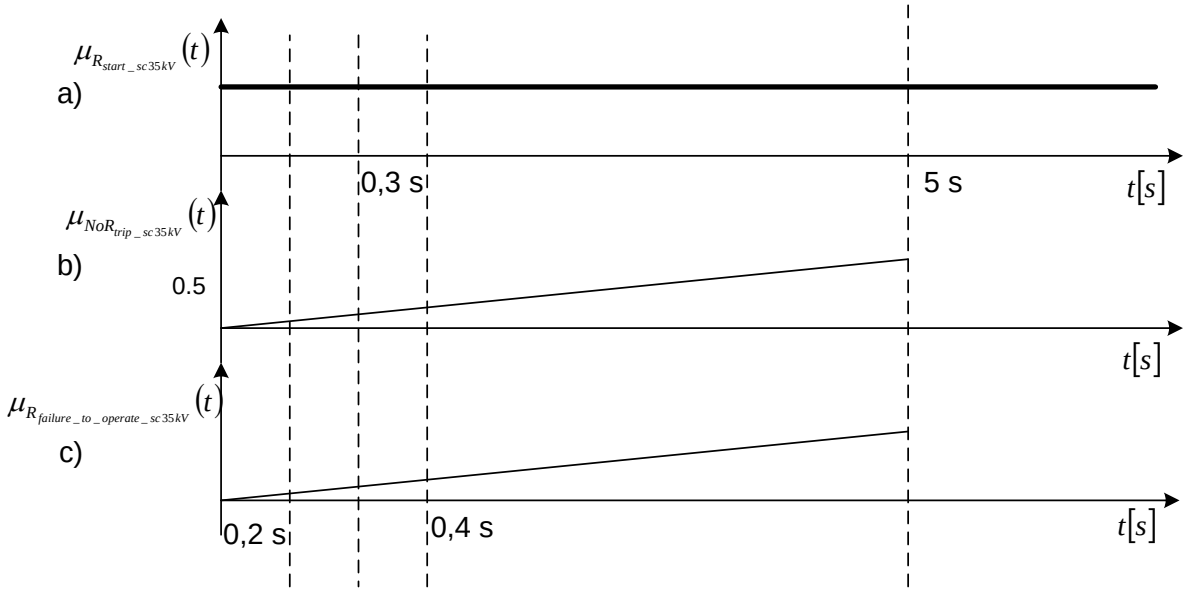


Slika 6.26: Funkcije pripadnosti krivog djelovanja kratkospojnog releja koji štiti dalekovod 35 kV

$$\mu_{R_{false_operation_sc35kV}}(t)=\mu_{R_{start_sc35kV}}(t)\cap\mu_{R_{trip_sc35kV}}(t)=\begin{cases}5t & t\in\langle 0 \quad 0.2\rangle\\ 1 & t\in\langle 0.2 \quad 0.24\rangle\\ -16.67t+5 & t\in\langle 0.24 \quad 0.3\rangle\\ 10t-3 & t\in\langle 0.3 \quad 0.4\rangle\\ 1 & t\in\langle 0.4 \quad 0.44\rangle\\ -6.25t+3.75 & t\in\langle 0.44 \quad 0.6\rangle\end{cases} \quad (6.25)$$

6.4.3. Otkazivanje djelovanja kratkospojnog releja koji štiti dalekovod 35 kV

Funkcija pripadnosti otkazivanja djelovanja kratkospojnog releja koji štiti dalekovod 35kV $\mu_{R_{failure_to_operate_sc35kV}}(t)$ prikazana je na slici 6.27c, a dobivena je pomoću relacije (6.26) kao presjek funkcije pripadnosti aktivnog stanja kratkospojnog releja koji štiti dalekovod 35kV $\mu_{R_{start_sc35kV}}(t)$ slika 6.27a i funkcije pripadnosti nepostojećeg stanja isključenja kratkospojnog releja koji štiti dalekovod 35 kV $\mu_{NoR_{trip_sc35kV}}(t)$ slika 6.27b.

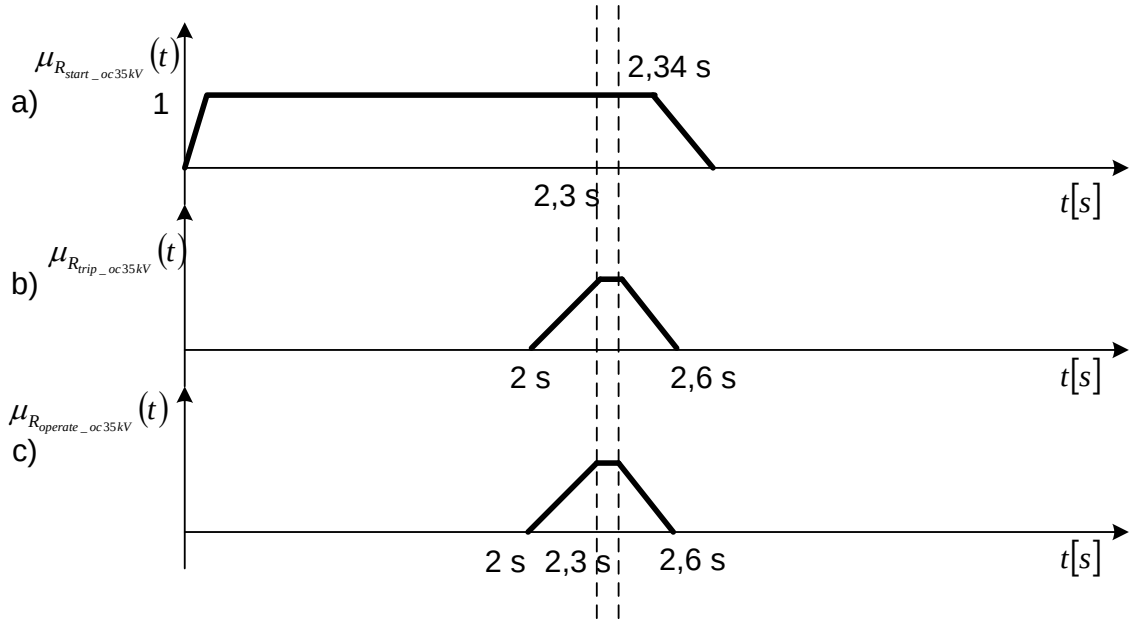


Slika 6.27: Funkcije pripadnosti otkazivanja djelovanja kratkospojnog releja koji štiti dalekovod 35 kV

$$\mu_{R_{failure_to_operate_sc35kV}}(t) = \mu_{R_{start_sc35kV}}(t) \cap \mu_{NoR_{trip_sc35kV}}(t) = 0.2t, \quad t \in \langle 0 \quad 5 \rangle \tag{6.26}$$

6.4.4. Ispravno djelovanje nadstrujnog releja koji štiti dalekovod 35 kV

Funkcija pripadnosti ispravnog djelovanja nadstrujnog releja koji štiti dalekovod 35 kV $\mu_{R_{operate_oc35kV}}(t)$ prikazana je na slici 6.28c, a dobivena pomoću relacije 6.27 iskazane kao presjek funkcije pripadnosti aktivnom stanju nadstrujnog releja koji štiti dalekovod 35 kV $\mu_{R_{start_oc35kV}}(t)$ slika 6.28a i funkcije pripadnosti stanju isključenja nadstrujnog releja koji štiti dalekovod 35 kV $\mu_{R_{trip_oc35kV}}(t)$ slika 6.28b.

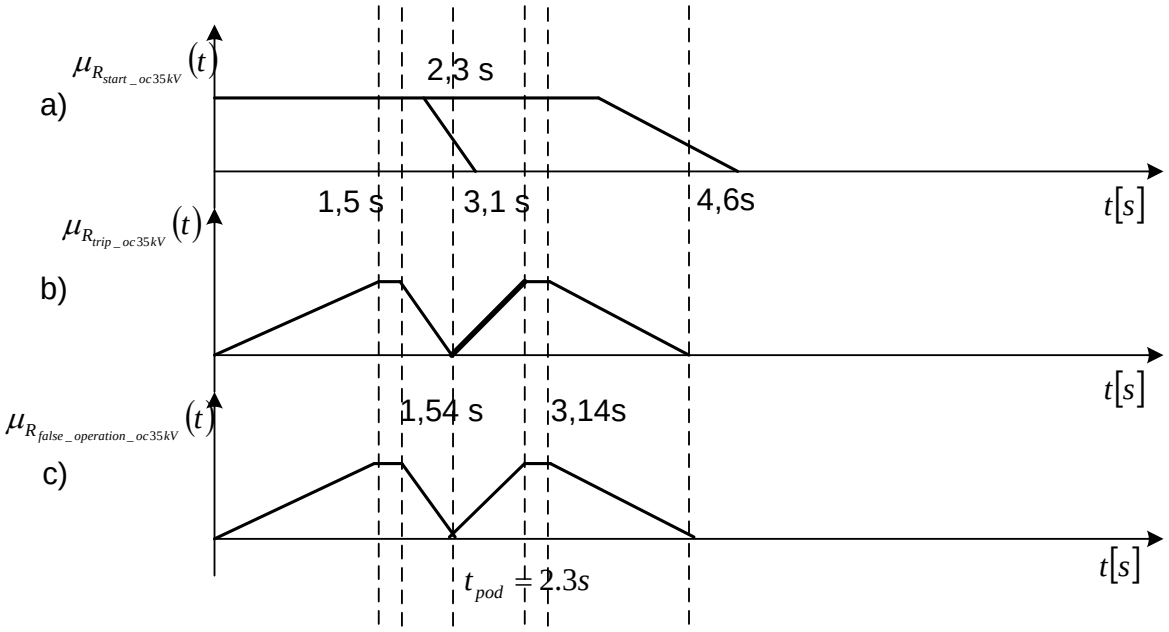


Slika 6.28: Funkcija pripadnosti ispravnog djelovanja nadstrujnog releja koji štiti dalekovod 35 kV

$$\mu_{R_{operate_oc35kV}}(t) = \mu_{R_{start_oc35kV}}(t) \cap \mu_{R_{trip_oc35kV}}(t) = \begin{cases} 3.34t - 6.67 & t \in \langle 2 \quad 2.3 \rangle \\ 1 & t \in \langle 2.3 \quad 2.34 \rangle \\ -3.85t + 10 & t \in \langle 2.34 \quad 2.6 \rangle \end{cases} \tag{6.27}$$

6.4.5. Krivo djelovanje nadstrujnog releja koji štiti dalekovod 35 kV

Funkcije pripadnosti aktivacijskih stanja prilikom krivog djelovanja nadstrujnog releja koji štiti dalekovod 35 kV $\mu_{R_{start_oc35kV}}(t)$ prikazani su na slici 6.29a za vremenski interval prije $t_{pod} = 2.3s$ i za vremenski interval nakon $t_{pod} = 2.3s$. Stanja isključenja prilikom krivog djelovanja nadstrujnog releja pomoću funkcije pripadnosti $\mu_{R_{trip_oc35kV}}(t)$ prikazana su na slici 6.29b za vremenski interval prije $t_{pod} = 2.3s$ i za vremenski interval nakon $t_{pod} = 2.3s$. Krivo djelovanje nadstrujnog releja koji štiti dalekovod 35kV $\mu_{R_{fales_operation_oc35kV}}(t)$ prikazano je pomoću funkcije pripadnosti na slici 6.29c i definirano relacijom (6.28), a grafički je dobiveno pomoću presjeka slika 6.29 (a i b).

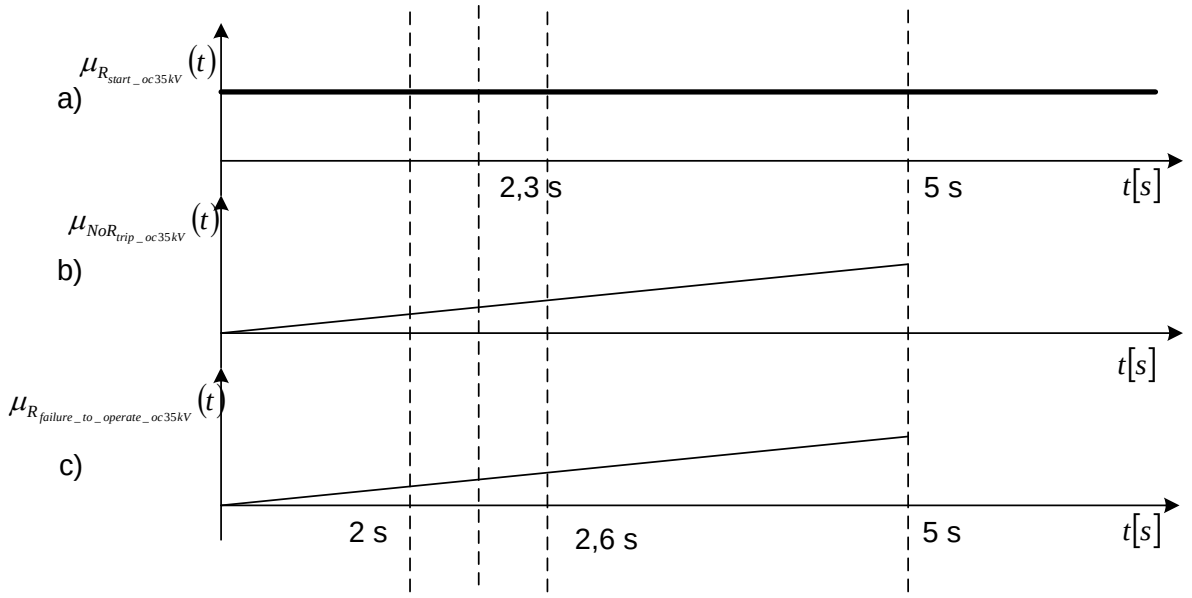


Slika 6.29: Funkcije pripadnosti krivog djelovanja nadstrujnog releja koji štiti dalekovod 35 kV

$$\mu_{R_{false_operation_oc35kV}}(t) = \mu_{R_{start_oc35kV}}(t) \cap \mu_{R_{trip_oc35kV}}(t) = \begin{cases} 0.67t & t \in \langle 0 \quad 1.5 \rangle \\ 1 & t \in \langle 1.5 \quad 1.54 \rangle \\ -1.32t + 3.03 & t \in \langle 1.54 \quad 2.3 \rangle \\ 1.25t - 2.875 & t \in \langle 2.3 \quad 3.1 \rangle \\ 1 & t \in \langle 3.1 \quad 3.14 \rangle \\ -0.68t + 3.15 & t \in \langle 3.14 \quad 4.6 \rangle \end{cases} \tag{6.28}$$

6.4.6. Otkazivanje djelovanja nadstrujnog releja koji štiti dalekovod 35 kV

Funkcija pripadnosti otkazivanja djelovanja nadstrujnog releja koji štiti dalekovod 35 kV $\mu_{R_{failure_to_operate_oc35kV}}(t)$ prikazana je na slici 6.30c, a dobivena je pomoću relacije (6.29) kao presjek funkcije pripadnosti aktivnom stanju nadstrujnog releja koji štiti dalekovod 35 kV $\mu_{R_{start_oc35kV}}(t)$ slika 6.30a i funkcije pripadnosti nepostojećeg stanja isključenja nadstrujnog releja koji štiti dalekovod 35 kV $\mu_{NoR_{trip_oc35kV}}(t)$ slika 6.30b.

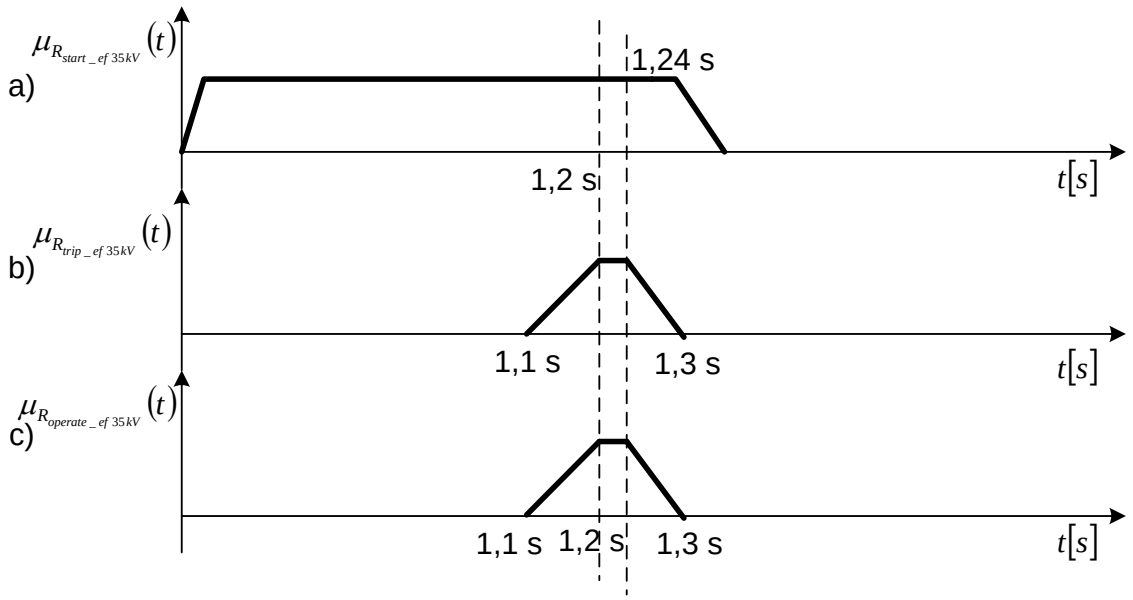


Slika 6.30: Funkcija pripadnosti otkazivanja djelovanja nadstrujnog releja koji štiti dalekovod 35 kV

$$\mu_{R_{failure_to_operate_oc35kV}}(t) = \mu_{R_{start_oc35kV}}(t) \cap \mu_{NoR_{trip_oc35kV}}(t) = 0.2t, \quad t \in \langle 0 \quad 5 \rangle \tag{6.29}$$

6.4.7. Ispravno djelovanje zemljospojnog releja koji štiti dalekovod 35 kV

Funkcija pripadnosti ispravnog djelovanja zemljospojnog releja koji štiti dalekovod 35 kV $\mu_{R_{operate_ef35kV}}(t)$ prikazana je na slici 6.31c, a dobivena je pomoću relacije (6.30) iskazane kao presjek funkcije pripadnosti aktivnog stanja zemljospojnog releja koji štiti dalekovod 35 kV $\mu_{R_{start_ef35kV}}(t)$ slika 6.31a i funkcije pripadnosti stanju isključenja zemljospojnog releja koji štiti dalekovod 35 kV $\mu_{R_{trip_ef35kV}}(t)$ slika 6.31b.

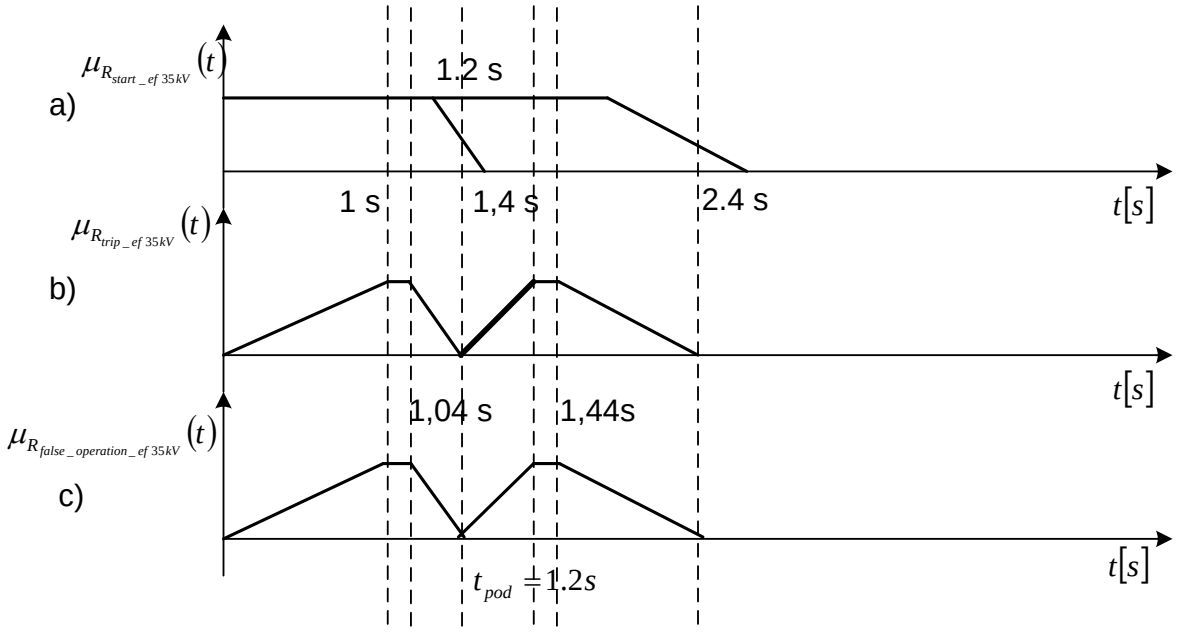


Slika 6.31: Funkcije pripadnosti ispravnog djelovanja zemljospojnog releja koji štiti dalekovod 35 kV

$$\mu_{R_{operate_ef\,35kV}}(t) = \mu_{R_{start_ef\,35kV}}(t) \cap \mu_{R_{trip_ef\,35kV}}(t) = \begin{cases} 10t - 11 & t \in \langle 1.1 \quad 1.2 \rangle \\ 1 & t \in \langle 1.2 \quad 1.24 \rangle \\ -16.67t + 21.67 & t \in \langle 1.24 \quad 1.3 \rangle \end{cases} \tag{6.30}$$

6.4.8. Krivo djelovanje zemljospojnog releja koji štiti dalekovod 35 kV

Funkcije pripadnosti aktivacijskih stanja prilikom krivog djelovanja zemljospojnog releja koji štiti dalekovod 35 kV $\mu_{R_{start_ef\,35kV}}(t)$ prikazane su na slici 6.32a za vremenski interval prije $t_{pod} = 1.2s$ i za vremenski interval nakon $t_{pod} = 1.2s$. Stanja isključenja prilikom krivog djelovanja zemljospojnog releja pomoću funkcije pripadnosti $\mu_{R_{trip_ef\,35kV}}(t)$ prikazana su na slici 6.32b za vremenski interval prije $t_{pod} = 1.2s$ i za vremenski interval nakon $t_{pod} = 1.2s$. Krivo djelovanje zemljospojnog releja koji štiti dalekovod 35kV $\mu_{R_{fales_operation_ef\,35kV}}(t)$ prikazano je pomoću funkcije pripadnosti na slici 6.32c i definirano relacijom (6.31), a grafički je dobiveno pomoću presjeka slika 6.32(a i b).

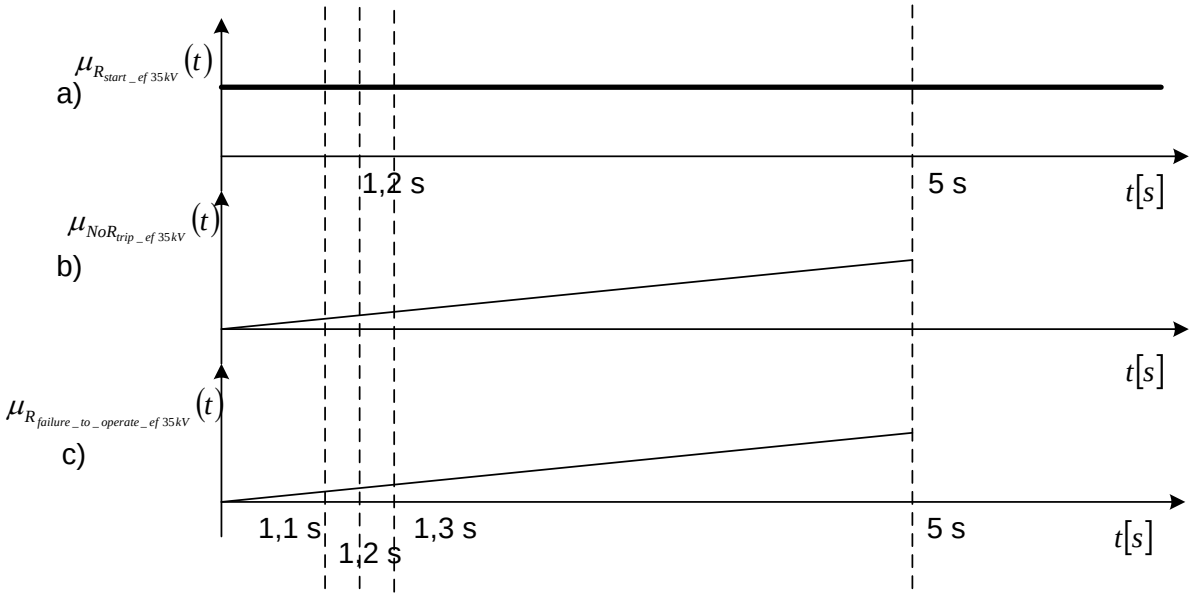


Slika 6.32: Funkcije pripadnosti krivog djelovanja zemljospojnog releja koji štiti dalekovod 35 kV

$$\mu_{R_{false_operation_ef\,35kV}}(t) = \mu_{R_{start_ef\,35kV}}(t) \cap \mu_{R_{trip_ef\,35kV}}(t) = \begin{cases} t & t \in \langle 0 \quad 1 \rangle \\ 1 & t \in \langle 1 \quad 1.04 \rangle \\ -6.25t + 7.5 & t \in \langle 1.04 \quad 1.2 \rangle \\ 5t - 6 & t \in \langle 1.2 \quad 1.4 \rangle \\ 1 & t \in \langle 1.4 \quad 1.44 \rangle \\ 1.04t + 2.5 & t \in \langle 1.44 \quad 2.4 \rangle \end{cases} \tag{6.31}$$

6.4.9. Otkazivanje djelovanja zemljospojnog releja koji štiti dalekovod 35 kV

Funkcija pripadnosti otkazivanja djelovanja zemljospojnog releja koji štiti dalekovod 35kV $\mu_{R_{failure_to_operate_ef\,35kV}}(t)$ prikazana je na slici 6.33c, a dobivena je pomoću relacije (6.32) kao presjek funkcije pripadnosti aktivnom stanju zemljospojnog releja koji štiti dalekovod 35kV $\mu_{R_{start_ef\,35kV}}(t)$ slika 6.33a i funkcije pripadnosti nepostojećeg stanja isključenja zemljospojnog releja koji štiti dalekovod 35 kV $\mu_{NoR_{trip_ef\,35kV}}(t)$ slika 6.33b.



Slika 6.33: Funkcije pripadnosti u odnosu na vrijeme kod otkazivanja djelovanja zemljospojnog releja

$$\mu_{R_{failure_to_operate_ef\,35kV}}(t) = \mu_{R_{start_ef\,35kV}}(t) \cap \mu_{NoR_{trip_ef\,35kV}}(t) = 0.2t, \quad t \in \langle 0 \quad 5 \rangle \tag{6.32}$$

6.5. Prekidači

Releji i prekidači u EES-u su uzročno-posljedično povezani zbog njihovog funkcionalnog djelovanja. Prilikom kvara relej šalje signal za isključenje R_{trip} te prekidač mora isključiti dionicu u kvaru (zonu štićenja) što se karakterizira kao ispravno djelovanje sustava. Funkcioniranje prekidača se može opisati kao ispravno djelovanje, krivo djelovanje i otkazivanje djelovanja. Ta djelovanja su opisana pomoću logičkih jednadžbi (6.33-6.35) izvedenih po modelu iz [27, 60]. Logičke jednadžbe funkcionalnih djelovanja prekidača iskazana su pomoću Booleove logike. Lijeva strana logičkih jednadžbi predstavlja funkcionalno djelovanje prekidača dok desna predstavlja uzročno-posljedičnu povezanost dva stanja (alarma). Ispravno djelovanje prekidača $CB_{operate}$ opisano je relacijom (6.33) koje predstavlja kombinaciju stanja isključenja R_{trip} i otvorenog stanja prekidača CB_{open}. Relacija (6.34) predstavlja krivo djelovanje prekidača $CB_{fals_operation}$ što znači kako je prekidač isključio bez impulsa za isključenje (sam od sebe). To je kombinacija nepostojećeg stanja isključenja (nepostojeća informacija) NoR_{trip} i otvorenog stanja prekidača CB_{open}. Otkazivanje djelovanja prekidača $CB_{failure_to_operate}$ opisano je relacijom (6.35) koja predstavlja kombinaciju stanja isključenja R_{trip} i zatvorenog stanja prekidača CB_{close} (nepostojeću informacija). Sve relacije su kombinacija stanja prekidača i releja. Iz relacija 6.33-6.35 se ne vidi direktno uzročno-posljedična veza nego samo logička kombinacija dva stanja (dvije informacije).

$$CB_{operate} = R_{trip} \cdot CB_{open} = R_{trip} \wedge CB_{open} \tag{6.33}$$

$$CB_{false_operation} = NoR_{trip} * CB_{open} = NoR_{trip} \wedge CB_{open} \tag{6.34}$$

$$CB_{failure_to_operate} = R_{trip} * CB_{close} = R_{trip} \wedge CB_{close} \tag{6.35}$$

Uvođenjem vremenskog uvjeta jednadžbe (6.33-6.35) prelaze u oblik (6.36-6.38).

$$\mathrm{CB}_{operate} = R_{trip} * CB_{open} = R_{trip} \wedge CB_{open} \ , \ t_{open} = t_{trip} + t_{djelovanja} \tag{6.36}$$

$$\mathrm{CB}_{false_operation} = NoR_{trip} * CB_{open} = NoR_{trip} \wedge CB_{open} \tag{6.37}$$

$$\mathrm{CB}_{faliure_to_operate} = R_{trip} * CB_{close} = R_{trip} \wedge CB_{close} \tag{6.38}$$

Usporedimo li relaciju (6.36) s relacijom (6.33) vidimo kako je relacija (6.36) proširena s vremenskim uvjetom koji kaže kako je vrijeme otvaranja prekidača t_{open} jednako vremenu stanja isključenja t_{trip} i vremenu djelovanja samog prekidača $t_{djelovanja}$. Vrijeme djelovanja prekidača $t_{djelovanja}$ u distributivnoj mreži je od 20-80 ms. U opisu modela vrijeme djelovanja prekidača iznosi $t_{djelovanja} = 40ms$.

- Novi način modeliranja funkcionalnih djelovanja prekidača (ispravno djelovanje, krivo djelovanje i otkazivanje djelovanja) pomoću neizrazite logike u vremenskoj domeni.

$$\mu_{CB_{operate}}(t) = \mu_{R_{trip}}(t) \cap \mu_{CB_{open}}(t), \quad t \in \langle 0.9t_{pod} + 40ms, \quad 1.1t_{pod} \rangle \tag{6.39}$$

$$\mu_{CB_{false_operation}}(t) = \mu_{NoR_{trip}}(t) \cap \mu_{CB_{open}}(t), \quad t \in [0.9t_{pod} + 40ms, \quad t_1) \tag{6.40}$$

$$\mu_{CB_{failure_to_operate}}(t) = \mu_{R_{trip}}(t) \cap \mu_{CB_{close}}(t), \quad t \in \langle 0.9t_{pod}, \quad 1.1t_{pod} \rangle \tag{6.41}$$

Ispravno djelovanje prekidača definirano je funkcijom pripadnosti $\mu_{CB_{operate}}(t)$ koje je jednako presjeku funkcije pripadnosti stanju isključenja $\mu_{R_{trip}}(t)$ i funkcije pripadnosti stanju otvorenog prekidača $\mu_{CB_{open}}(t)$ u vremenskom intervalu od $0.9t_{pod} + 40ms$ do deset postotnom vremenu većem od podešenog $1.1t_{pod}$ (6.39).

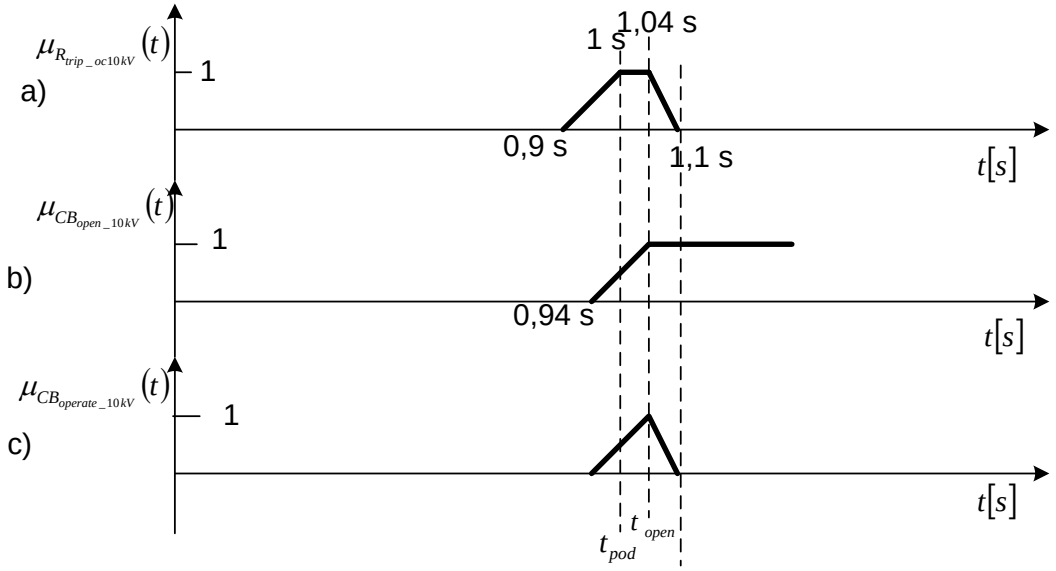
Krivo djelovanje prekidača definirano je funkcijom pripadnosti $\mu_{CB_{false_operation}}(t)$ koje je jednako presjeku funkcije pripadnosti nepostojećem stanju isključenja $\mu_{NoR_{trip}}(t)$ i funkcije pripadnosti stanju otvorenog prekidača $\mu_{CB_{open}}(t)$ u vremenskom intervalu od $0.9t_{pod} + 40ms$ do t1 koje je veće od dvostrukog vremenska parametra releja $2\,t_{pod}$ (6.40).

Funkcija pripadnosti koja opisuje otkazivanje djelovanja prekidača $\mu_{CB_{failure_to_operate}}(t)$ jednaka je presjeku funkcije pripadnosti stanju isključenja releja $\mu_{R_{trip}}(t)$ i funkcije pripadnosti zatvorenom stanju prekidača $\mu_{CB_{close}}(t)$ u vremenskom intervalu $\pm 10\%$ od vremenskog parametra releja t_{pod} (6.41).

6.6. Dalekovod 10 kV

6.6.1. Ispravno djelovanje prekidača dalekovoda 10 kV

Funkcija pripadnosti ispravnog djelovanja prekidača dalekovoda 10 kV $\mu_{CB_{operate_10kV}}(t)$ opisana je relacijom (6.42) i prikazana slikom 6.34c koja je jednaka presjeku funkcije pripadnosti stanju isključenja nadstrujnog releja koji štiti dalekovod 10 kV $\mu_{R_{trip_oc10kV}}(t)$ slika 6.34a i funkcije pripadnosti otvorenog stanja prekidača $\mu_{CB_{open_10kV}}(t)$ slika 6.34b.



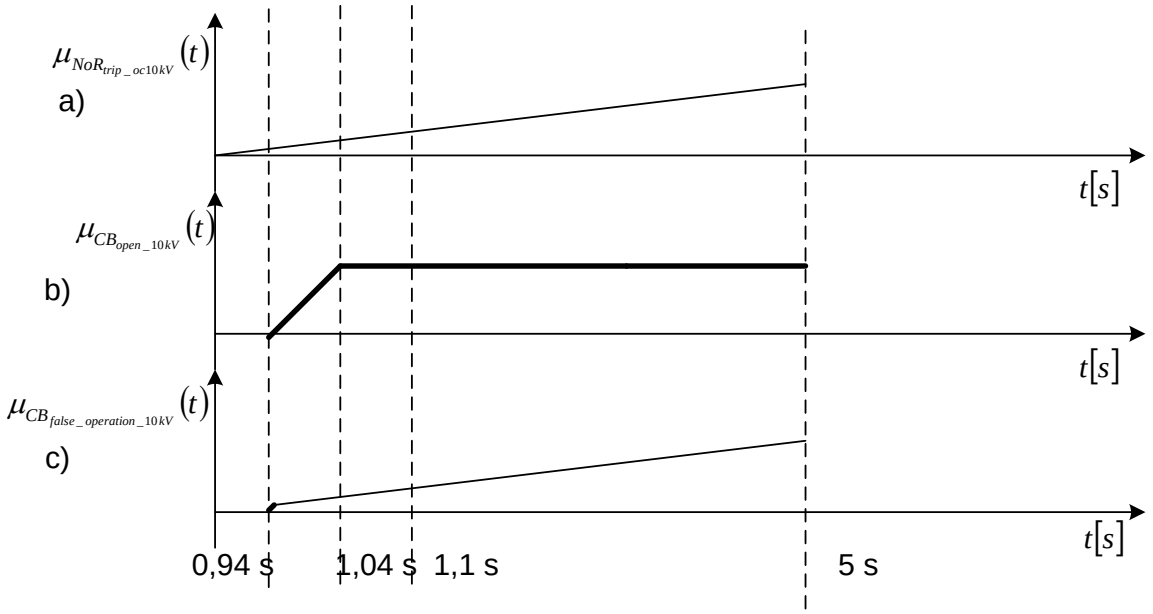
Slika 6.34: Funkcija pripadnosti ispravnog djelovanja prekidača dalekovoda 10 kV

$$\mu_{CB_{operate_10kV}}(t) = \mu_{R_{trip_oc10kV}}(t) \cap \mu_{CB_{open_10kV}}(t) = \begin{cases} 10t - 9.4 & t \in \langle 0.94 \quad 1.04 \rangle \\ -16.67t + 18.34 & t \in \langle 1.04 \quad 1.1 \rangle \end{cases} \tag{6.42}$$

6.6.2. Krivo djelovanje prekidača dalekovoda 10 kV

Funkcija pripadnosti krivog djelovanja prekidača dalekovoda 10 kV $\mu_{CB_{false_operation_10kV}}(t)$ opisana je relacijom (6.43) i prikazana slikom 6.35c koja je jednaka presjeku funkcije

pripadnosti nepostojećeg stanja isključenja nadstrujnog releja koji štiti dalekovod 10 kV $\mu_{NoR_{trip_oc10kV}}(t)$ slika 6.35a (nepostojeća informacija) i funkcije pripadnosti otvorenog stanja prekidača dalekovoda 10 kV $\mu_{CB_{open_10kV}}(t)$ slika 6.35b.

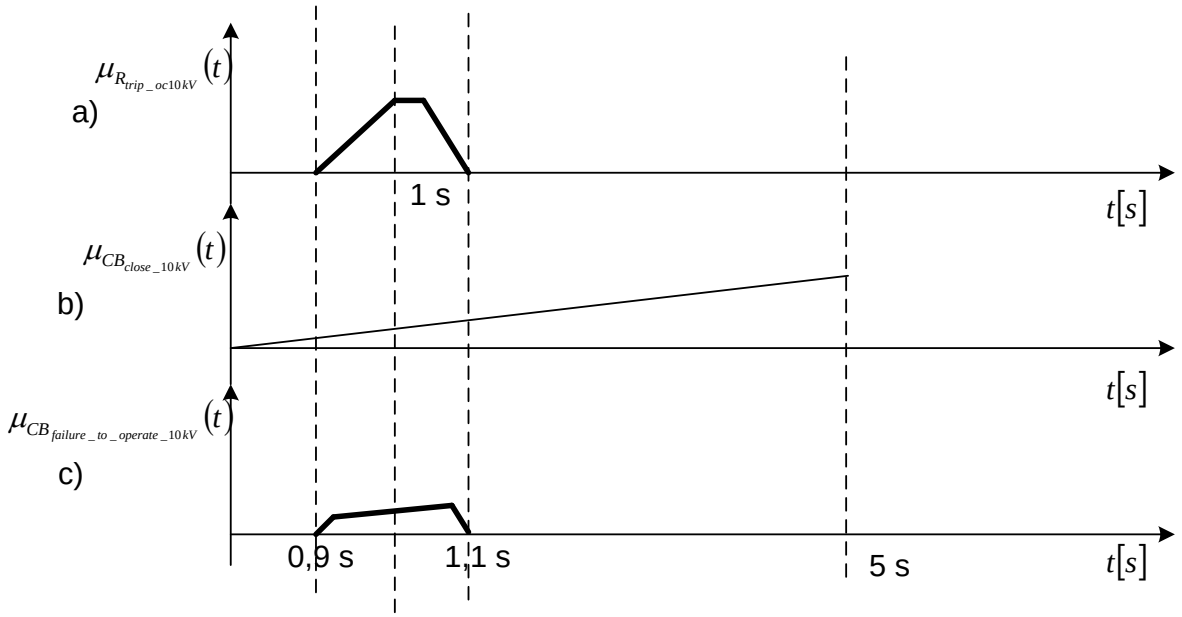


Slika 6.35: Funkcija pripadnosti krivog djelovanja prekidača dalekovoda 10 kV

$$\mu_{CB_{false_operation_10kV}}(t) = \mu_{NoR_{trip_oc10kV}}(t) \cap \mu_{CB_{open_10kV}}(t) = \begin{cases} 10t - 9.4 & t \in \langle 0.94 \quad 0.96 \rangle \\ 0.2t & t \in \langle 0.96 \quad 5 \rangle \end{cases} \tag{6.43}$$

6.6.3. Otkazivanje djelovanja prekidača dalekovoda 10 kV

Funkcija pripadnosti otkazivanja djelovanja prekidača dalekovoda 10 kV $\mu_{CB_{failure_to_operate_10kV}}(t)$ opisana je relacijom (6.44) i prikazana slikom 6.36c koja je jednaka presjeku funkcije pripadnosti stanju isključenja nadstrujnog releja koji štiti dalekovod 10 kV $\mu_{R_{trip_oc10kV}}(t)$ slika 6.36a i funkcije pripadnosti zatvorenog stanja prekidača dalekovoda 10 kV $\mu_{CB_{close_10kV}}(t)$ (nepostojeća informacija) slika 6.36b.



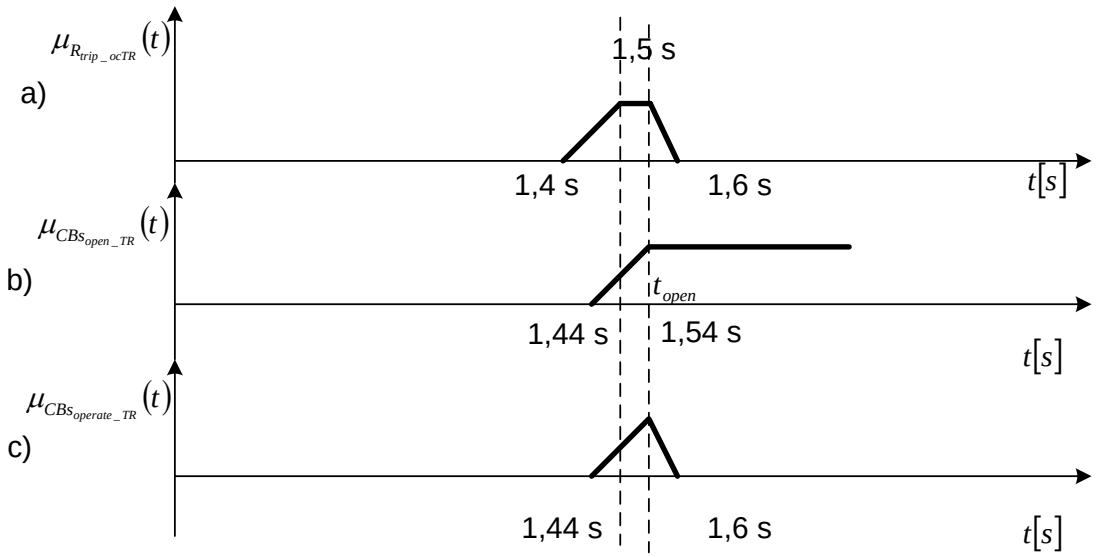
Slika 6.36: Funkcija pripadnosti otkazivanje djelovanja prekidača dalekovoda 10 kV

$$\mu_{CB_{failure_to_operate_10kV}}(t) = \mu_{R_{trip_oc10kV}}(t) \cap \mu_{CB_{close_10kV}}(t) = \begin{cases} 10t - 9 & t \in \langle 0.9 \quad 0.92 \rangle \\ 0.2t & t \in \langle 0.92 \quad 1.09 \rangle \\ -16.67t + 18.34 & t \in \langle 1.09 \quad 1.1 \rangle \end{cases} \tag{6.44}$$

6.7. Transformatorsko polje

6.7.1. Ispravno djelovanje oba prekidača transformatora

Funkcija pripadnosti ispravnog djelovanja oba prekidača transformatora $\mu_{CBs_{operate_TR}}(t)$ opisana je relacijom (6.45) i prikazana slikom 6.37c koja je jednaka presjeku funkcije pripadnosti stanju isključenja nadstrujnog releja koji štiti transformator $\mu_{R_{trip_ocTR}}(t)$ slika 6.37a i funkcije pripadnosti otvorenom stanju oba prekidača $\mu_{CBs_{open_TR}}(t)$ slika 6.37b.

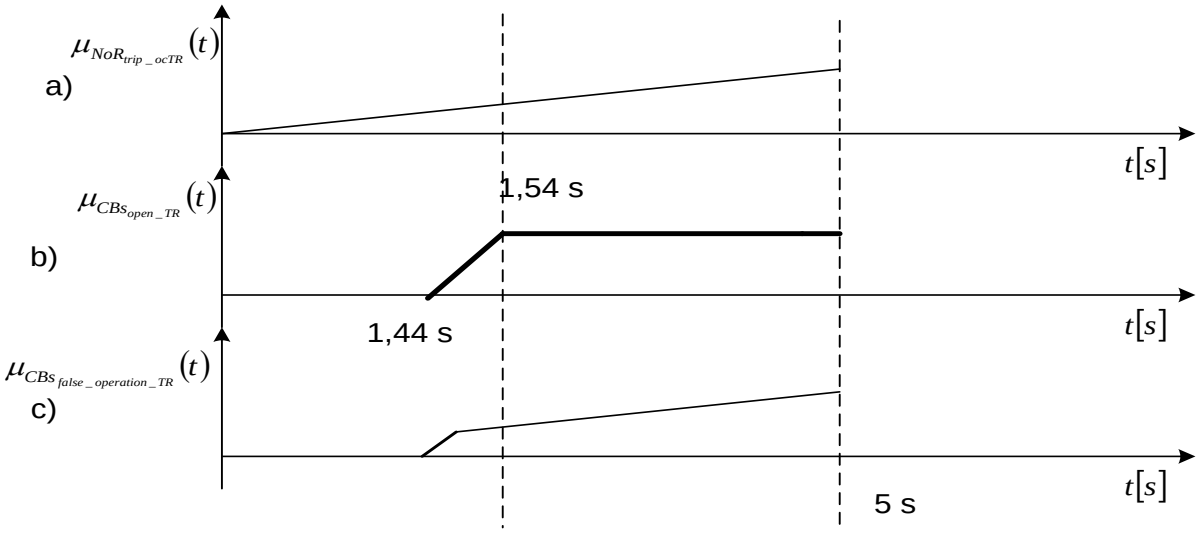


Slika 6.37: Funkcija pripadnosti ispravnog djelovanja oba prekidača transformatora

$$\mu_{CBs_{operate_TR}}(t) = \mu_{R_{trip_ocTR}}(t) \cap \mu_{CBs_{open_TR}}(t) = \begin{cases} 10t - 14.4 & t \in \langle 1.44 \quad 1.54 \rangle \\ -16.67 + 26.67 & t \in \langle 1.54 \quad 1.6 \rangle \end{cases} \tag{6.45}$$

6.7.2. Krivo djelovanje oba prekidača transformatora

Funkcija pripadnosti krivog djelovanja oba prekidača transformatora $\mu_{CBs_{false_operation_TR}}(t)$ opisana je relacijom (6.46) i prikazana slikom 6.38c koja je jednaka presjeku funkcije pripadnosti nepostojećeg stanja isključenja nadstrujnog releja koji štiti transformator $\mu_{NoR_{trip_ocTR}}(t)$ slika 6.38a (nepostojeća informacija) i funkcije pripadnosti otvorenog stanja oba prekidača transformatora $\mu_{CBs_{open_TR}}(t)$ slika 6.38b.

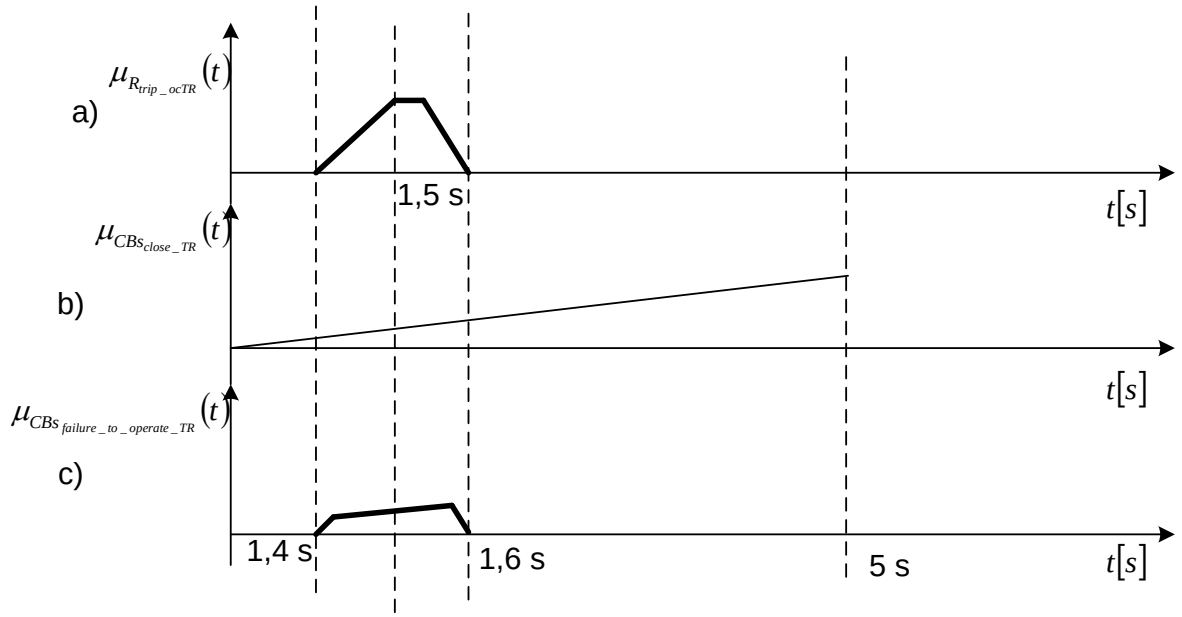


Slika 6.38: Funkcija pripadnosti krivog djelovanja oba prekidača transformatora

$$\mu_{CBs_{false_operation_TR}}(t) = \mu_{NoR_{trip_ocTR}}(t) \cap \mu_{CBs_{open_TR}}(t) = \begin{cases} 10t - 14.4 & t \in \langle 1.44 \quad 1.47 \rangle \\ 0.2t & t \in \langle 1.47 \quad 5 \rangle \end{cases} \tag{6.46}$$

6.7.3. Otkazivanje djelovanja oba prekidača na transformatora

Funkcija pripadnosti otkazivanja djelovanja oba prekidača transformatora $\mu_{CBs_{failure_to_operate_TR}}(t)$ opisana je relacijom (6.47) i prikazana slikom 6.39c koja je jednaka presjeku funkcije pripadnosti stanju isključenja nadstrujnog releja koji štiti transformator $\mu_{R_{trip_ocTR}}(t)$ slika 6.39a i funkcije pripadnosti zatvorenom stanju oba prekidača transformatora $\mu_{CB_{close_TR}}(t)$ (nepostojeća informacija) slika 6.39b.



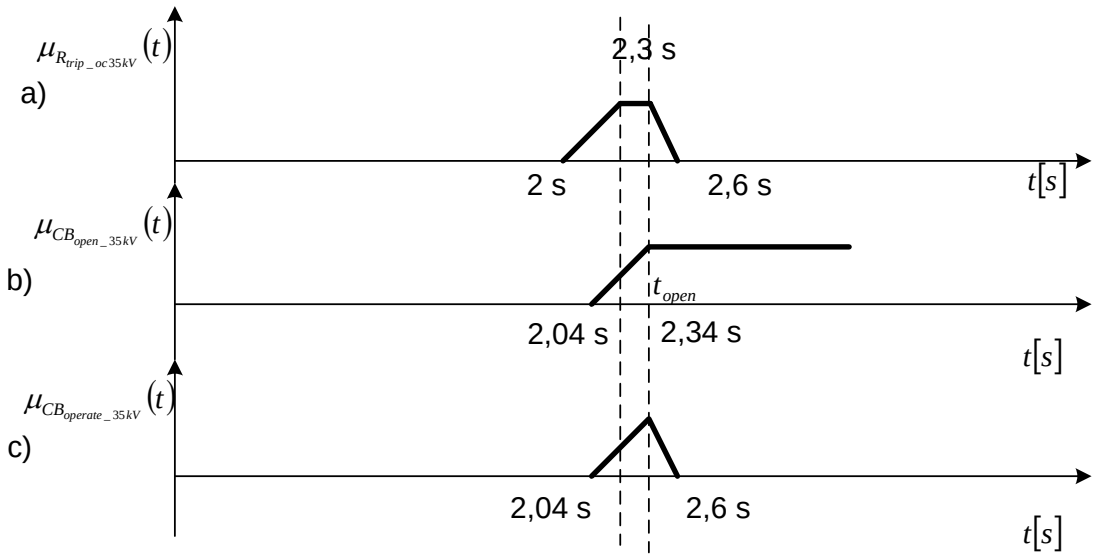
Slika 6.39: Funkcija pripadnosti otkazivanje djelovanja oba prekidača transformatora

$$\mu_{CBs_{fail_to_operate_TR}}(t) = \mu_{R_{trip_ocTR}}(t) \cap \mu_{CBs_{close_TR}}(t) = \begin{cases} 10t - 14 & t \in \langle 1.4 \quad 1.43 \rangle \\ 0.2t & t \in \langle 1.43 \quad 1.58 \rangle \\ -16.67t + 26.67 & t \in \langle 1.58 \quad 1.6 \rangle \end{cases} \tag{6.47}$$

6.8. Dalekovod 35 kV

6.8.1. Ispravno djelovanje prekidača dalekovoda 35 kV

Funkcija pripadnosti ispravnog djelovanja prekidača dalekovoda 35 kV $\mu_{CB_{operate_35kV}}(t)$ opisana je relacijom (6.48) i prikazana slikom 6.40c koja je jednaka presjeku funkcije pripadnosti stanju isključenja nadstrujnog releja koji štiti dalekovod 35 kV $\mu_{R_{trip_oc35kV}}(t)$ slika 6.40a i funkcije pripadnosti otvorenom stanju prekidača dalekovoda 35 kV $\mu_{CB_{open_35kV}}(t)$ slika 6.40b.

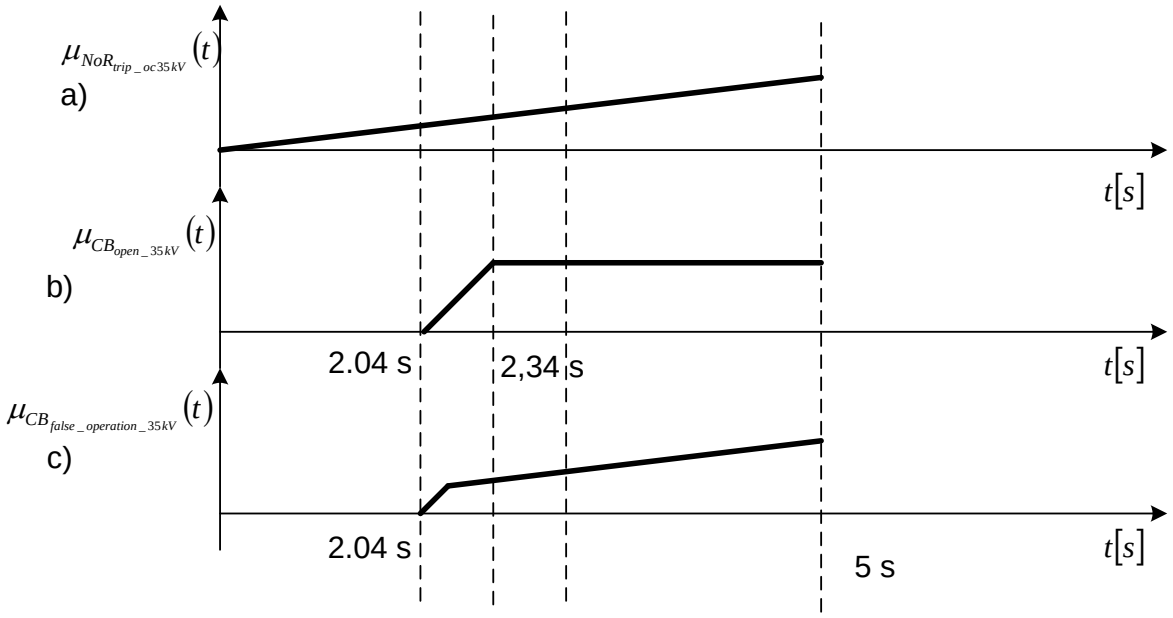


Slika 6.40: Funkcija pripadnosti ispravnog djelovanja prekidača dalekovoda 35 kV

$$\mu_{CB_{operate_35kV}}(t) = \mu_{R_{trip_oc35kV}}(t) \cap \mu_{CB_{open_35kV}}(t) = \begin{cases} 3.34t - 6.8 & t \in \langle 2.04 \quad 2.34 \rangle \\ -3.85t + 10 & t \in \langle 2.34 \quad 2.6 \rangle \end{cases} \tag{6.48}$$

6.8.2. Krivo djelovanje prekidača dalekovoda 35 kV

Funkcija pripadnosti krivog djelovanja prekidača dalekovoda 35 kV $\mu_{CB_{false_operation_35kV}}(t)$ opisana je relacijom (6.49) i prikazana slikom 6.41c koja je jednaka presjeku funkcije pripadnosti nepostojećeg stanja isključenja nadstrujnog releja koji štiti dalekovod 35 kV $\mu_{NoR_{trip_oc35kV}}(t)$ slika 6.41a (nepostojeća informacija) i funkcije pripadnosti otvorenog stanja prekidača dalekovoda 35 kV $\mu_{CB_{open_35kV}}(t)$ slika 6.41b.

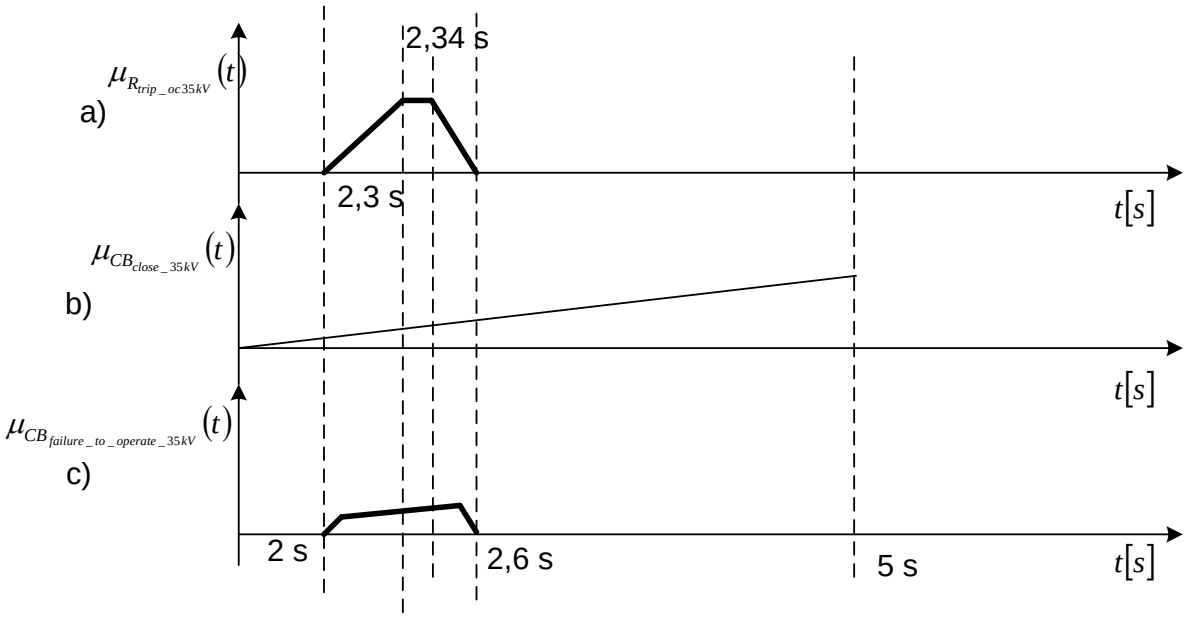


Slika 6.41: Funkcija pripadnosti krivog djelovanja prekidača dalekovoda 35 kV

$$\mu_{CB_{false_operation_35kV}}(t) = \mu_{R_{trip_oc35kV}}(t) \cap \mu_{CB_{open_35kV}}(t) = \begin{cases} 3.34t - 6.67 & t \in \langle 2 \quad 2.17 \rangle \\ 0.2t & t \in \langle 2.17 \quad 5 \rangle \end{cases} \tag{6.49}$$

6.8.3. Otkazivanje djelovanja prekidača dalekovoda 35 kV

Funkcija pripadnosti otkazivanja djelovanja prekidača dalekovoda 35 kV $\mu_{CB_{failure_to_operate_35kV}}(t)$ opisana je relacijom (6.50) i prikazana slikom 6.42c koja je jednaka presjeku funkcije pripadnosti stanju isključenja nadstrujnog releja koji štiti dalekovod 35 kV $\mu_{R_{trip_oc35kV}}(t)$ slika 6.42a i funkcije pripadnosti zatvorenom stanju prekidača dalekovoda 35 kV $\mu_{CB_{close_35kV}}(t)$ (nepostojeća informacija) slika 6.42b.



Slika 6.42: Funkcija pripadnosti otkazivanje djelovanja prekidača dalekovoda 35 kV

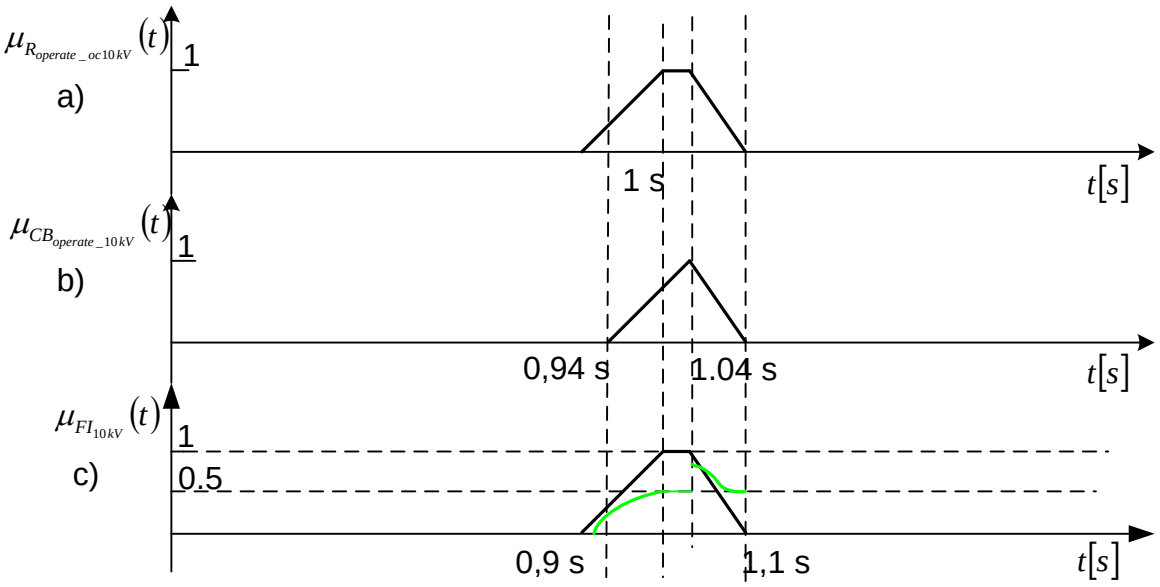
$$\mu_{CB_{failure_to_operate_35kV}}(t) = \mu_{R_{trip_oc35kV}}(t) \cap \mu_{CB_{close_35kV}} = \begin{cases} 3.34t - 6.67 & t \in \langle 2, \quad 2.12 \rangle \\ 0.2t & t \in \langle 2.12, \quad 2.47 \rangle \\ -3.85t + 10 & t \in \langle 2.47, \quad 2.6 \rangle \end{cases} \qquad (6.50)$$

6.9. Identifikacija kvara

6.10. Jednostruki kvarovi

6.10.1. Identifikacija kvara na dalekovodu 10 kV

Funkcija pripadnosti ispravnog djelovanja nadstrujne zaštite koja štiti dalekovod 10 kV $\mu_{R_{operate_oc10kV}}(t)$ prikazana je na slici 6.43a, a funkcija pripadnosti ispravnog djelovanja prekidača dalekovoda 10 kV $\mu_{CB_{operate_10kV}}(t)$ prikazana je na slici 6.43b. Identifikacija kvara na dalekovodu 10 kV $\mu_{FI_{10kV}}(t)$ slika 6.43c zelena krivulja (crna funkcija je prikaz identifikacije kvara pomoću maksimalnog operatora) određena je pomoću hibridnog operatora unije relacija (6.51).



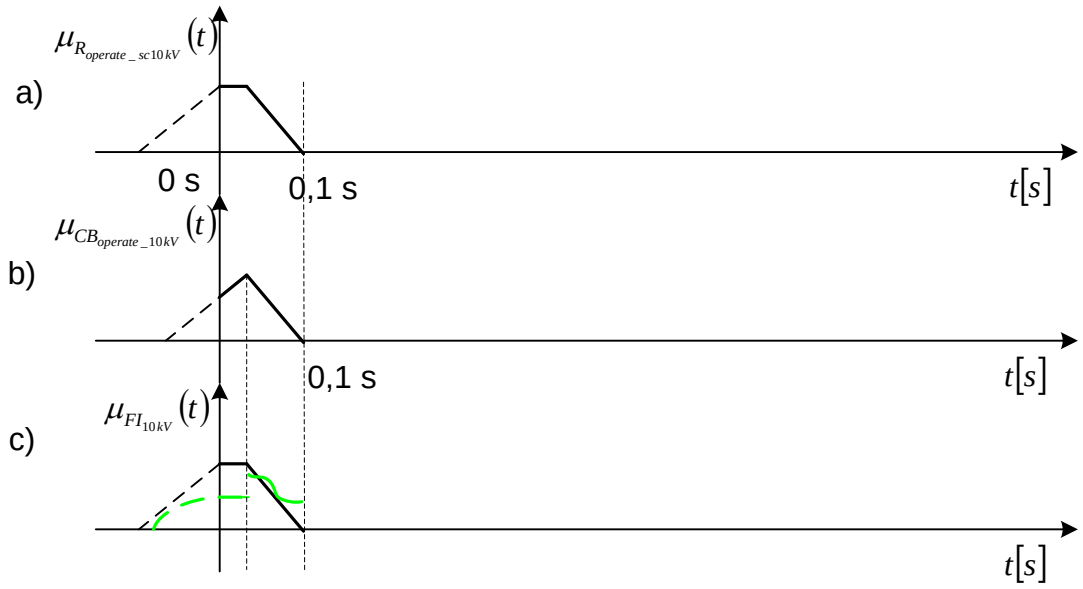
Slika 6.43: Funkcija pripadnosti identifikacije kvara na dalekovodu 10 kV

Hibridini operator unije prikazan je relacijom (6.51).

$$\mu_{FI_{10kV}}(t) = \mu_{R_{operate_oc10kV}}(t) \cup \mu_{CB_{operate_10kV}}(t) = \frac{2\mu_{R_{op}} + 2\mu_{CB_{op}} - 3\mu_{R_{op}} \cdot \mu_{CB_{op}} - \mu^2{}_{R_{op}} - \mu_{R_{op}} \cdot \mu_{CB_{op}}{}^2 + \mu_{R_{op}}{}^2 \cdot \mu_{CB_{op}}{}^2}{2 - 2\mu_{R_{op}} \cdot \mu_{CB_{op}}} \quad \textbf{(6.51)}$$

6.10.2. Identifikacija kvara na dalekovodu 10 kV

Funkcija pripadnosti ispravnog djelovanja kratkospojne zaštite koja štiti dalekovod 10 kV $\mu_{R_{operate_sc10kV}}(t)$ prikazana je na slici 6.44a, a funkcija pripadnosti ispravnog djelovanja prekidača dalekovoda 10 kV $\mu_{CB_{operate_10kV}}(t)$ prikazana je na slici 6.44b. Identifikacija kvara na dalekovodu 10 kV $\mu_{FI_{10kV}}(t)$ slika 6.44c zelena krivulja (crna funkcija je prikaz identifikacije kvara pomoću maksimalnog operatora) određena je pomoću hibridnog operatora unije relacija (6.52).

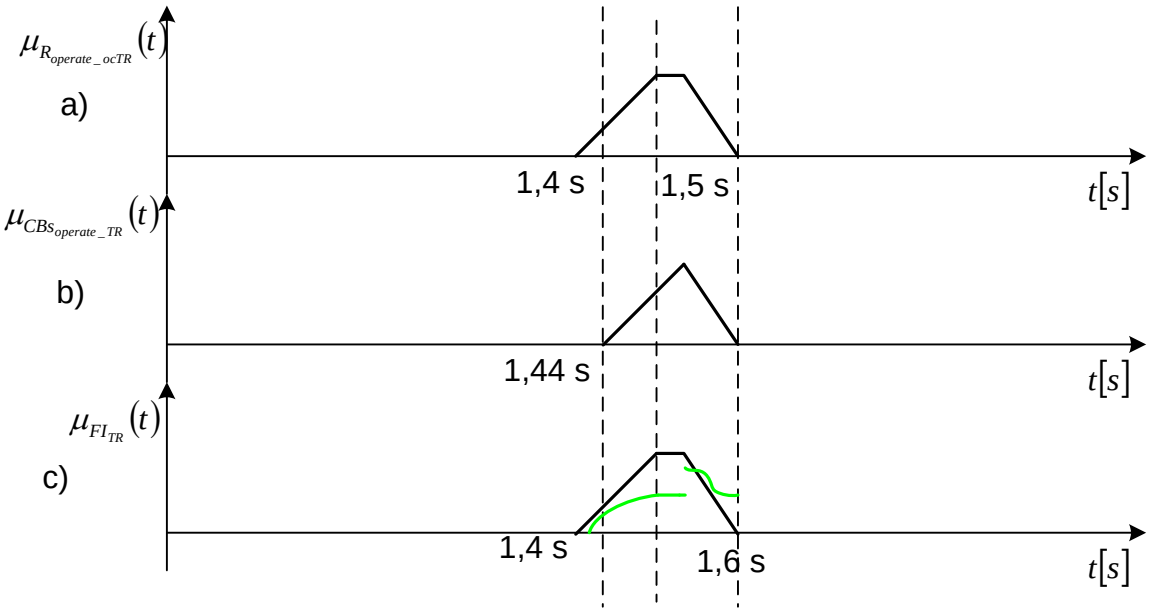


Slika 6.44: Funkcija pripadnosti identifikaciji kvara na dalekovodu 10 kV

$$\mu_{FI_{10kV}}(t) = \mu_{R_{operate_sc10kV}}(t) \cup \mu_{CB_{operate_10kV}}(t) = \frac{2\mu_{R_{op}} + 2\mu_{CB_{op}} - 3\mu_{R_{op}} \cdot \mu_{CB_{op}} - \mu^2{}_{R_{op}} - \mu_{R_{op}} \cdot \mu_{CB_{op}}{}^2 + \mu_{R_{op}}{}^2 \cdot \mu_{CB_{op}}{}^2}{2 - 2\mu_{R_{op}} \cdot \mu_{CB_{op}}} \tag{6.52}$$

6.10.3. Identifikacija kvara u štićenoj zoni transformatora

Funkcija pripadnosti ispravnog djelovanja nadstrujne zaštite koja štiti transformator $\mu_{R_{operate_ocTR}}(t)$ prikazana je na slici 6.45a, a funkcija pripadnosti ispravnog djelovanja oba prekidača transformatora $\mu_{CBs_{operate_TR}}(t)$ prikazana je na slici 6.45b. Identifikacija kvara na transformatoru $\mu_{FI_{TR}}(t)$ slika 6.45c zelena krivulja (crna funkcija je prikaz identifikacije kvara pomoću maksimalnog operatora) određena je pomoću hibridnog operatora unije relacija (6.53).



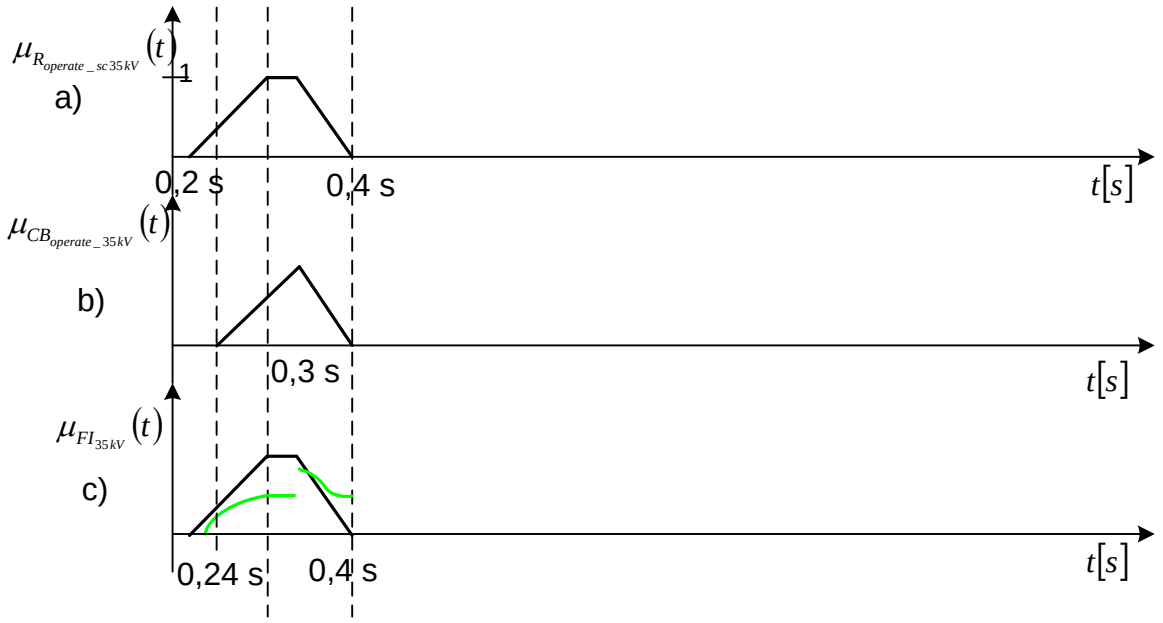
Slika 6.45: Funkcija pripadnosti identifikaciji kvara na transformatorskom polju

$$\mu_{FI_{TR}}(t) = \mu_{R_{operate_ocTR}}(t) \cup \mu_{CBs_{operate_TR}}(t) = \tag{6.53}$$

$$\frac{2\mu_{R_{op}} + 2\mu_{CBs_{op}} - 3\mu_{R_{op}} \cdot \mu_{CBs_{op}} - \mu^{2}{}_{R_{op}} - \mu_{R_{op}} \cdot \mu_{CBs_{op}}{}^{2} + \mu_{R_{op}}{}^{2} \cdot \mu_{CBs_{op}}{}^{2}}{2 - 2\mu_{R_{op}} \cdot \mu_{CBs_{op}}}$$

6.10.4. Identifikacija kvara na dalekovodu 35 kV (kratkospojna)

Funkcija pripadnosti ispravnog djelovanja kratkospojne zaštite koja štiti dalekovod 35 kV $\mu_{R_{operate_sc35kV}}(t)$ prikazana je na slici 6.46a, a funkcija pripadnosti ispravnog djelovanja prekidača dalekovoda 35 kV $\mu_{CB_{operate_35kV}}(t)$ prikazana je na slici 6.46b. Identifikacija kvara na dalekovodu 35 kV $\mu_{FI_{35kV}}(t)$ slika 6.46c zelena krivulja (crna funkcija je prikaz identifikacije kvara pomoću maksimalnog operatora) određena je pomoću novog operatora unije relacija (6.54).



Slika 6.46: Funkcija pripadnosti identifikaciji kvara na dalekovodu 35 kV

Hibridni operator unije prikazan pomoću relacije (6.54) pomoću kojeg se određuje lokacija kvara na dalekovodu 35 kV.

$$\mu_{FI_{35kV}}(t) = \mu_{R_{operate_sc35kV}}(t) \cup \mu_{CB_{operate_35kV}}(t) =$$

$$\frac{2\mu_{R_{op}} + 2\mu_{CB_{op}} - 3\mu_{R_{op}} \cdot \mu_{CB_{op}} - \mu^{2}{}_{R_{op}} - \mu_{R_{op}} \cdot \mu_{CB_{op}}{}^{2} + \mu_{R_{op}}{}^{2} \cdot \mu_{CB_{op}}{}^{2}}{2 - 2\mu_{R_{op}} \cdot \mu_{CB_{op}}} \tag{6.54}$$

6.11. Dvostruki kvarovi

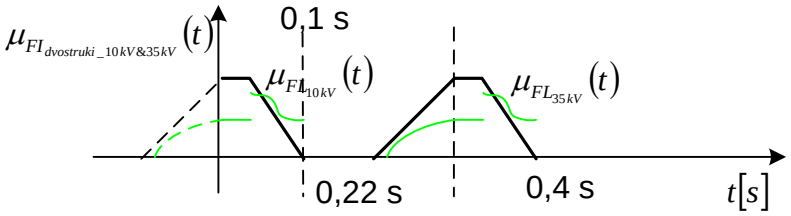
6.11.1. Dvostruki kvar na dalekovodu 10 kV i dalekovodu 35 kV

Dvostruki kvar je poremećaj koji se dogodio na dvije sekcije (dalekovod 35 kV i dalekovod 10 kV). Funkcija pripadnosti identifikaciji kvara na dalekovodu 10 kV $\mu_{FI_{10kV}}(t)$ i funkcija pripadnosti identifikaciji kvara na dalekovodu 35 kV $\mu_{FI_{35kV}}(t)$ su međusobno vremenski razmaknute slika 6.47. Funkcija pripadnosti dvostrukom kvaru $\mu_{FI_{dvostruki10kV\&35kV}}(t)$ uključuje funkciju pripadnosti identifikaciji kvara na dalekovodu 10 kV $\mu_{FI_{10kV}}(t)$ i funkciju

pripadnosti identifikaciji kvara na dalekovodu 35 kV $\mu_{FI_{35kV}}(t)$ što je iskazano pomoću relacije (6.56).

$$\mu_{FI_{dvostruki_10kV\&35kV}}(t) = \mu_{FI_{10kV}}(t) \wedge \mu_{FI_{35kV}}(t) = \min(\mu_{FI_{10kV}}, \mu_{FI_{35kV}}) \tag{6.56}$$

Dvostruki kvar jednak je minimalnoj vrijednosti jednostrukog kvara na dalekovodu 10 kV i dalekovodu 35 kV relacija (6.56).



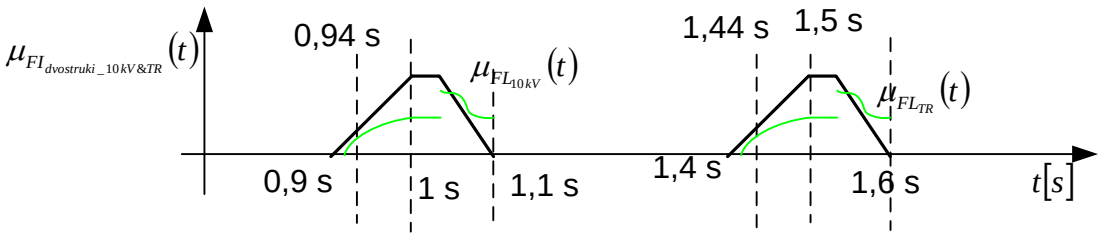
Slika 6.47: Funkcija pripadnosti kvara na dalekovodu 10 kV i dalekovodu 35 kV

6.11.2. Dvostruki kvar na dalekovodu 10 kV i transformatoru

Dvostruki kvar je poremećaj koji se dogodio na dvije sekcije (dalekovod 10 kV i transformator). Funkcija pripadnosti identifikaciji kvara dalekovoda 10 kV $\mu_{FI_{10kV}}(t)$ i funkcija pripadnosti identifikaciji kvara na transformatoru $\mu_{FI_{TR}}(t)$ su međusobno vremenski razmaknute slika 6.48. Funkcija pripadnosti dvostrukom kvaru $\mu_{FI_{dvostruki10kV\&TR}}(t)$ uključuje funkciju pripadnosti identifikacije kvara na dalekovodu 10 kV $\mu_{FI_{10kV}}(t)$ i funkciju pripadnosti identifikacije kvara na transformatoru $\mu_{FI_{TR}}(t)$ što je iskazano pomoću relacije (6.57).

$$\mu_{FI_{dvostruki_10kV\&TR}}(t) = \mu_{FI_{10kV}}(t) \wedge \mu_{FI_{TR}}(t) = \min(\mu_{FI_{10kV}}, \mu_{FI_{TR}}) \tag{6.57}$$

Dvostruki kvar jednak je minimalnoj vrijednosti jednostrukog kvara na dalekovodu 10 kV i transformatoru definirano relacijom (6.57).



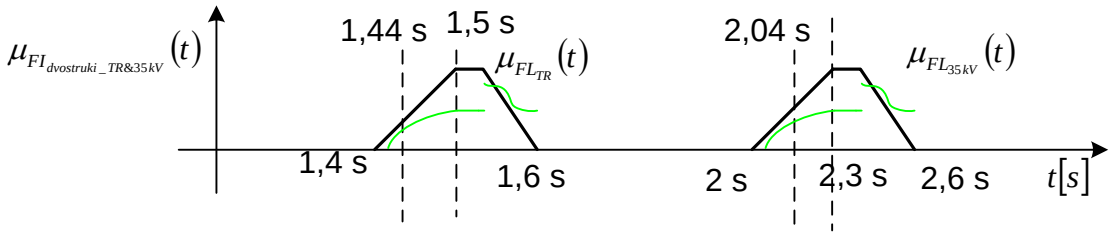
Slika 6.48: Funkcija pripadnosti za simultani kvar na dalekovodu 10 kV i transformatorskom polju

6.11.3. Dvostruki kvar na dalekovodu 35 kV i transformatoru

Dvostruki kvar je poremećaj koji se dogodio na dvije sekcije (transformator i dalekovod 35 kV). Funkcija pripadnosti identifikaciji kvara na dalekovodu 35 kV $\mu_{FI_{35kV}}(t)$ i funkcija pripadnosti identifikaciji kvara na transformatoru $\mu_{FI_{TR}}(t)$ su međusobno vremenski razmaknute slika 6.49. Funkcija pripadnosti dvostrukom kvaru $\mu_{FI_{dvostruk35kV\&TR}}(t)$ uključuje funkciju pripadnosti identifikacije kvara na dalekovodu 35 kV $\mu_{FI_{35kV}}(t)$ i funkciju pripadnosti identifikacije kvara na transformatoru $\mu_{FL_{TR}}(t)$ što je iskazano pomoću relacije (6.58).

$$\mu_{FI_{dvostruki}}(t) = \mu_{FI_{35kV}}(t) \wedge \mu_{FI_{TR}}(t) = \min(\mu_{FI_{35kV}}, \mu_{FI_{TR}}) \tag{6.58}$$

Dvostruki kvar jednak je minimalnoj vrijednosti jednostrukog kvara na dalekovodu 10 kV i transformatoru relacija (6.58).

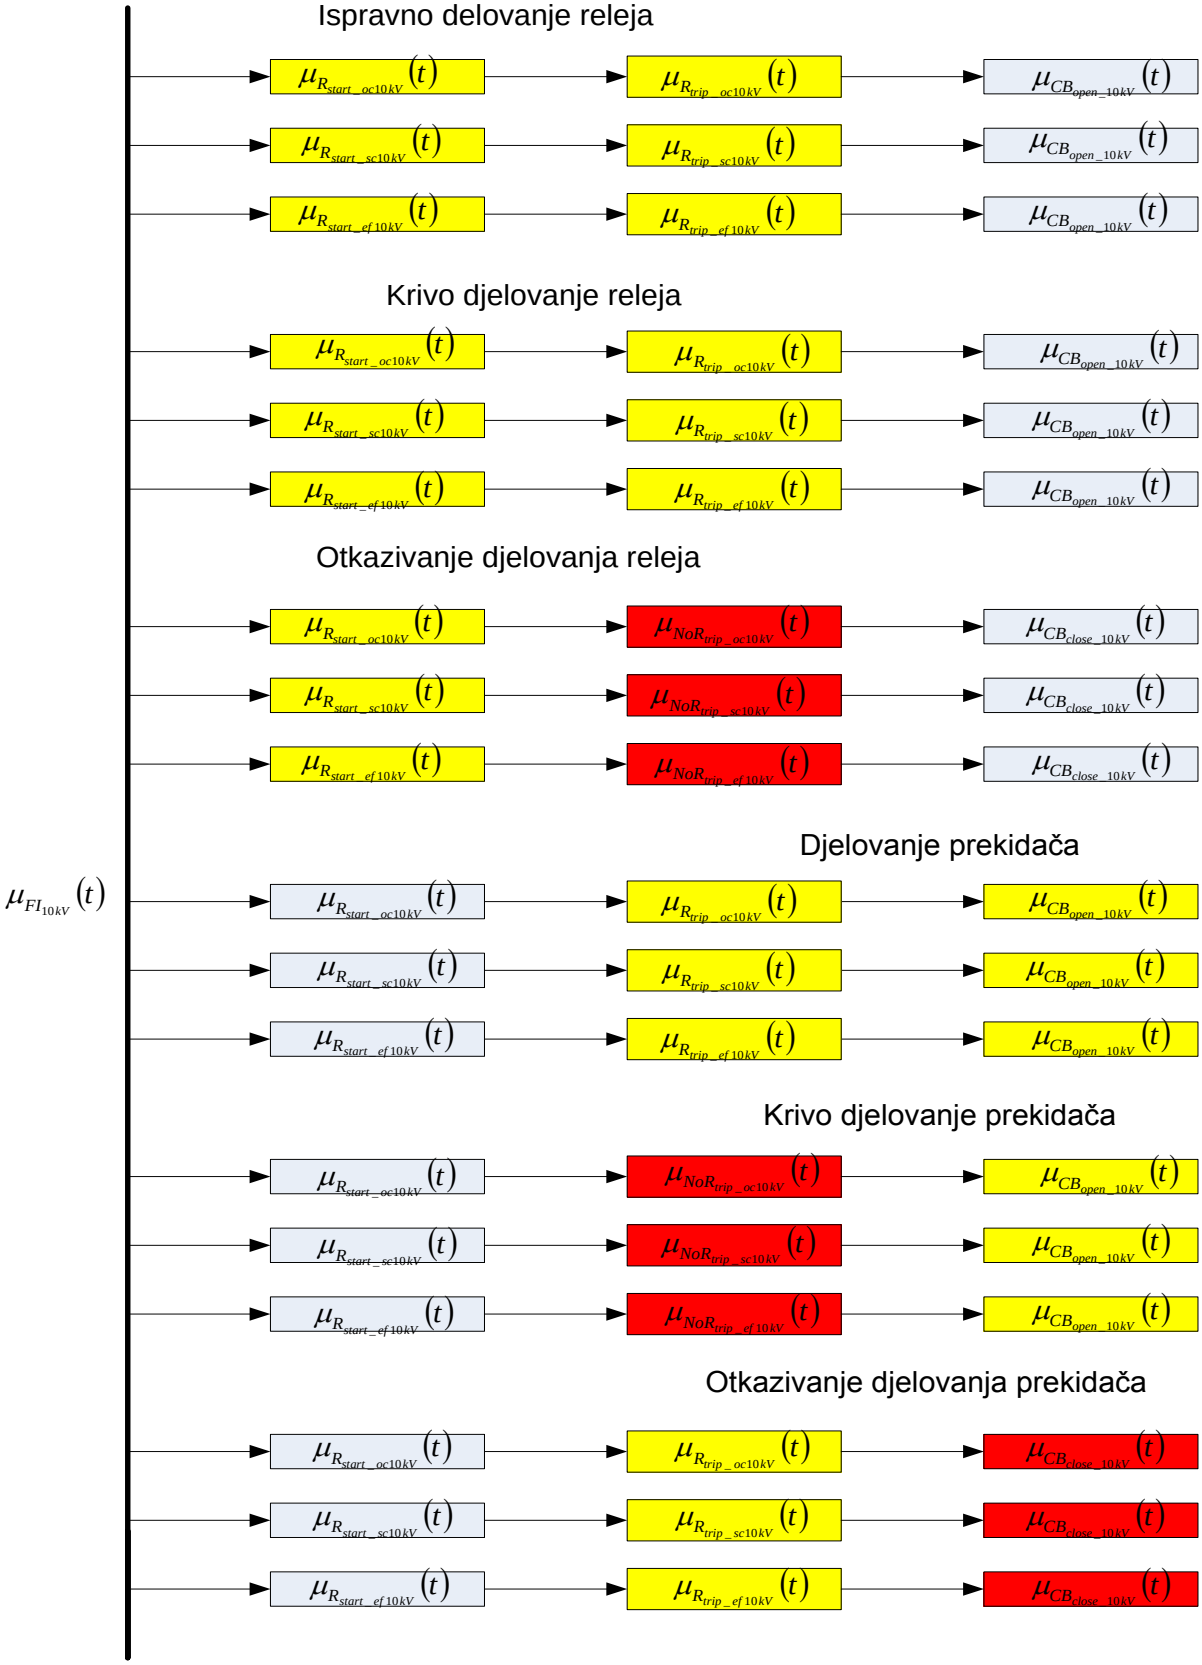


Slika 6.49: Funkcija pripadnosti za simultani kvar na transformatorskom polju i dalekovodu 35 kV

6.12. Sagitalni dijagrami

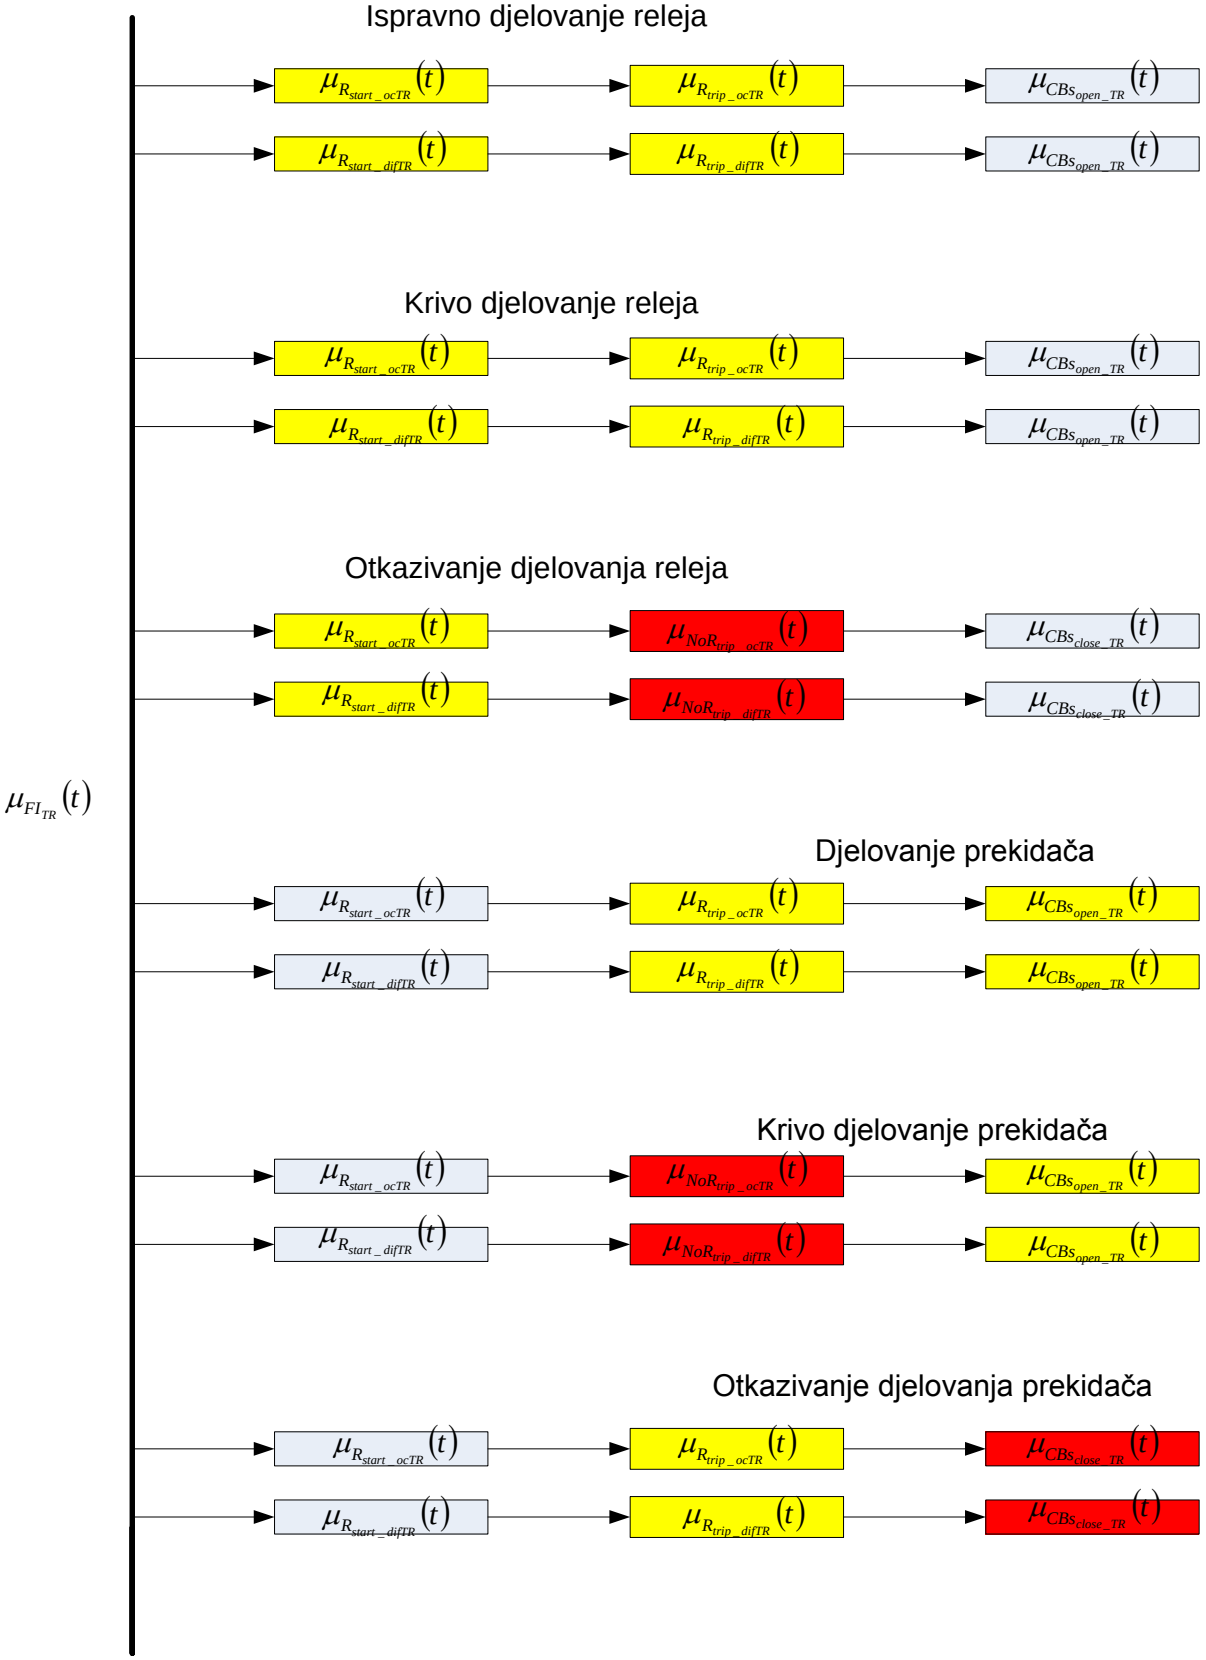
Sagitalni dijagrami (engl. sagittal diagram) prvi puta su uvedeni u neizrazitu logiku 1997. godine [153]. Opisuju uzročno-posljedičnu vezu alarma (stanja) s lokacijom kvara. Najčešće se ta uzročno posljedična veza alarma naziva putanja alarma. U pozadini putanje alarma krije se funkcionalna povezanost (uzročno-posljedična veza) kvara i releja te releja i prekidača. Smjer uzroka prema posljedici ide od lijeva na desno prikazano strelicom. Sagitalni dijagrami [150, 153, 155] predstavljaju objedinjen prikaz alarma (funkcije pripadnosti određenom stanju) i identifikaciju kvara. Sagitalni dijagrami prikazani na slikama 6.50, 6.51, 6.52 odnose se model dijela distributivne mreže sa slike 6.7. Na slici 6.50 prikazan je sagitalni dijagram koji se odnosi na dalekovod 10 kV. Dijagram sačinjava šest funkcionalnih djelovanja od čega se tri odnose na releje, a tri na prekidače (ispravno djelovanje, krivo djelovanje i otkazivanje djelovanja). Ispravno djelovanje releja, krivo djelovanje i otkazivanje djelovanja prikazano je za sve tri zaštite (nadstrujna, kratkospojna i zemljospojna) koje se nalaze na dalekovodu 10 kV. Za dijagnozu funkcionalnog djelovanja potrebna su minimalno dva alarma(stanja), a ti su alarmi obojani na slikama 6.50, 6.51 i 6.52. Žuto obojani alarmi označavaju prisustvo tih alarma (funkcije pripadnosti stanju) na zaslonu KRD-a te se jednostavno dolazi do dijagnoze. Crveno obojani pravokutnici su nepostojeći alarmi (nepostojeća informacija; funkcija pripadnosti nepostojećem stanju) koji se modeliraju kako bi se uz prisustvo samo jednog poznatog alarma (stanja) mogla donijeti dijagnoza s određenom sigurnošću. Otkazivanje djelovanja releja čini žuto-crvena kombinacija pravokutnika gdje je žuto obojan alarm aktiviranja releja (funkcija pripadnosti aktivacijskom stanju releja $\mu_{R_{start_}}(t)$), a crveni pravokutnik označava nopostojanje alarma isključenja (relej nije poslao impuls za isključenje; funkcija pripadnosti nepostojećeg stanja isključenja releja $\mu_{NoR_{trip_}}(t)$) slika 6.50. Unutar logičkih kombinacija koristite se nepostojeće informacije za što je izrazito pogodna neizrazita logika. Plavkasti pravokutnici označavaju alarm (stanje; funkciju pripadnosti stanju) koji se ne koristi u dijagnozi, a pojavljuju se na početku ili na kraju putanje alarma. Slika 6.50 prikazuje sagitalni dijagram dalekovodnog polja 10 kV. Sagitalni dijagram podijeljen je na šest djelovanja od čega se tri odnose na releje (ispravno djelovanje, krivo djelovanje i otkazivanje djelovanja releja), a tri se odnose na prekidače (ispravno djelovanje, krivo djelovanje i otkazivanje djelovanja prekidača). Odozgo prema dolje na slici 6.50 prvo nailazimo na ispravno djelovanje releja koje je dodatno podijeljeno u ispravno djelovanje nadstrujnog, ispravno djelovanje kratkospojnog i ispravno djelovanje

zemljospojnog releja. Za dijagnozu ispravnog djelovanja bilo kojeg releja na dalekovodu 10 kV potrebna su dva poznata alarma (funkcija pripadnosti aktivnom stanju releja $\mu_{R_{start_}}(t)$ i funkcija pripadnosti stanju isključenja $\mu_{R_{trip_}}(t)$). Drugo u nizu prikazano je krivo djelovanje nadstrujnog, kratkospojnog i zemljospojnog releja. Za dijagnozu krivog djelovanja nadstrujnog, kratkospojnog i zemljospojnog releja potrebna dva alarma (funkcija pripadnosti aktivnom stanju releja $\mu_{R_{start_}}(t)$ i funkcija pripadnosti stanju isključenja $\mu_{R_{trip_}}(t)$) kao i kod ispravnog djelovanja releja. Treće u nizu je prikazano otkazivanje djelovanja releja (nadstrujnog, kratkospojnog i zemljospojnog) koje se definira pomoću poznatog alarma (funkcije pripadnosti aktivacijskom stanju releja; $\mu_{R_{start_}}(t)$) i nepostojećeg alarma isključenja (funkcije pripadnosti nepostojećem stanju isključenja $\mu_{NoR_{trip_}}(t)$) koji je obojan crveno. Otkazivanje djelovanja releja predstavlja aktivaciju releja te pojavu alarma aktivnosti releja na KRD-u (funkcija pripadnosti aktivacijskom stanju releja $\mu_{R_{start_}}(t)$), ali ne i alarma za isključenje na zaslonu KRD-a (funkcija pripadnosti nepostojećem stanju isključenja $\mu_{NoR_{trip_}}(t)$). Četvrto u nizu je prikazano ispravno djelovanje prekidača čiji je uzrok djelovanja relej (nadstrujni, kratkospjni i zemljospojni). Dijagnoza ispravnog djelovanja prekidača se definira pomoću dva poznata alarma (funkcija pripadnosti stanju isključenja $\mu_{R_{trip_}}(t)$ i funkcija pripadnosti stanju otvorenog prekidača $\mu_{CB_{open_}}(t)$) te su oba prisutna na KRD-u. Peto u nizu je prikazano krivo djelovanje prekidača koje se definira pomoću nepostojećeg alarma (funkcije pripadnosti nepostojećem stanju isključenja $\mu_{NoR_{trip_}}(t)$) i alarma otvorenog prekidača (funkcije pripadnosti stanju otvorenog prekidača $\mu_{CB_{open_}}(t)$). Krivo djelovanje prekidača znači kako zaštita nikad nije djelovala (nemamo informaciju na KRD-u) tj. poslala signal isključenja prema prekidaču, a prekidač se otvorio sam od sebe. Šesto u nizu na slici 6.50 je prikazano otkazivanje djelovanja prekidača koje se može definirati kao kombinacija alarma (funkcije pripadnosti stanju isključenja $\mu_{R_{trip_}}(t)$ i nepostojeće informacije tj. funkcije pripadnosti zatvorenom stanju prekidača $\mu_{CB_{close_}}(t)$). Otkazivanje djelovanja prekidača znači kao je zaštita ispravno djelovala te poslala signal isključenja, a prekidač je ostao zatvoren (ta informacije je također nepoznata).



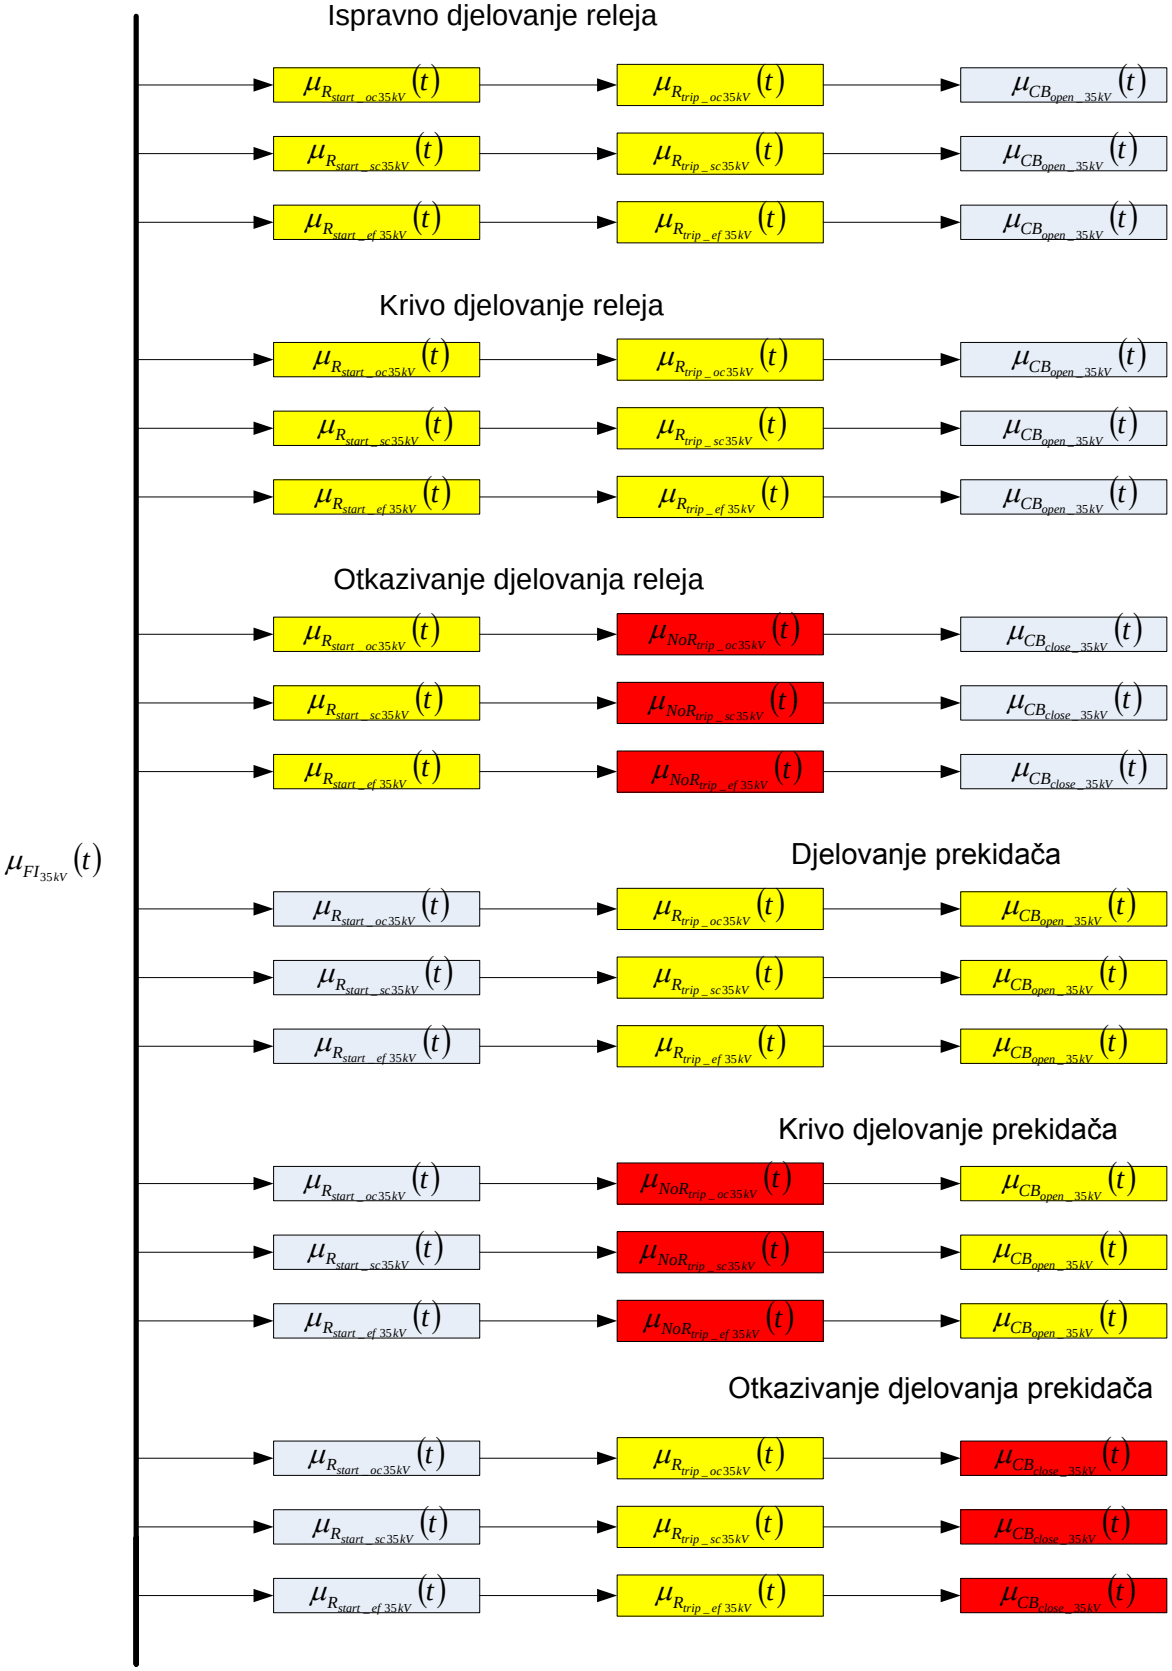
Slika 6.50: Sagitalni dijagram stanja (alarma) za dalekovod 10 kV

Sagitalni dijagram transformatorskog polja prikazan je na slici 6.51 na kojemu je definirano šest djelovanja od čega se tri odnose na releje, a tri na prekidače transformatorskog polja. Transformator štite dva releja (nadstrujni i diferencijalani). Odozgo prema dolje na slici 6.51 prvo je definirano ispravno djelovanje releja (nadstrujnog i diferencijalnog). Ispravno djelovanje releja definira se pomoću dva poznata alarma koji su uzročno-posljedično povezani što znači kao je zaštita aktivirana te nakon podešenog vremena poslala signal za isključenje. Drugo u nizu je prikazano krivo djelovanje zaštite (nadstrujne i diferencijalne) slika 6.51 koje se definira pomoću alarma aktivnog stanja releja (funkcije pripadnosti aktivnom stanju releja $\mu_{R_{start_}}(t)$) alarma isključenja (funkcije pripadnosti stanju isključenja $\mu_{R_{trip_}}(t)$). Treće u nizu je otkazivanje djelovanja releja (nadstrujnog i diferencijalnog) kojim se definira alarm aktivacije releja (funkcije pripadnosti aktivnom stanju releja $\mu_{R_{start_}}(t)$) i nepostojećeg alarma isključenja (funkcije pripadnosti nepostojećem stanju isključenja $\mu_{NoR_{trip_}}(t)$). Logička kombinacija kaže kako je došlo do aktiviranja zaštite (nadstrujne ili diferencijalne), ali nije došlo do slanja signala isključenja iz bilo kojeg razloga te koristimo nepostojeću informaciju (funkcije pripadnosti nepostojećem stanju isključenja $\mu_{NoR_{trip_}}(t)$). Četvrto djelovanje u nizu na sagitalnom dijagramu slika 6.51 prikazuje ispravno djelovanje prekidača. Dijagnoza ispravnog djelovanja prekidača bazira se na uzročno-posljedičnoj vezi alarma isključenja (funkcije pripadnosti stanju isključenja $\mu_{R_{trip_}}(t)$) i oba alarma otvorenog prekidača (funkcije pripadnosti stanju isključenosti oba prekidača $\mu_{CBs_{open_}}(t)$). Funkcionalno to znači kako je nakon slanja signala isključenja (relej) došlo do isključenja (otvaranja) oba prekidača. Peto u nizu je prikazano krivo djelovanje oba prekidača koje je opisano pomoću nepostojećeg alarma isključenja (funkcije pripadnosti nepostojećem stanju isključenja $\mu_{NoR_{trip_}}(t)$) i alarma otvorenih prekidača (oba) (funkcija pripadnosti otvorenom stanju oba prekidača $\mu_{CBs_{open_}}(t)$). Otkazivanje djelovanja oba prekidača na transformatorskom polju slika 6.51 prikazano je kao šesto u nizu. Otkazivanje djelovanja prekidača definira se pomoću alarma isključenja (funkcije pripadnosti stanju isključenja $\mu_{R_{trip_}}(t)$) i nepostojećih alarma otvorenosti oba prekidača (funkcija pripadnosti nepostojećem stanju otvorenosti oba prekidača $\mu_{CBs_{close_}}(t)$). Funkcionalno stanje otkazivanja djelovanja prekidača događa se kada relej pošalje signal za isključenje, a prekidači ostanu zatvoreni.



Slika 6.51: Sagitalni dijagram alarma za transformatorsko polje

Sagitalni dijagram dalekovodnog polja 35 kV prikazan je na slici 6.52 kojeg štite tri releja (nadstrujni, kratkospojni i zemljospojni). Na sagitalnom dijagramu slika 6.52 prikazano je šest djelovanja komponenti od kojih se tri odnose na releje, a tri na prekidače. Odozgo prema dolje prvo je definirano ispravno djelovanje kojeg čini isprano djelovanje nadstrunog, kratkospojnog i zemljospojnog releja. Ispravno djelovanje releja se definira pomoću alarma aktivacije releja (funkcije pripadnosti aktivnom stanju releja $\mu_{R_{start_}}(t)$) i alarma impulsa za isključenje (funkcije pripadnosti stanju isključenja $\mu_{R_{trip_}}(t)$) slika 6.52. Drugo u nizu je definirano krivo djelovanje releja (nadstrujnog, kratkospojnog i zemljospojnoog) pomoću alarma aktivacije releja (funkcije pripadnosti aktivnom stanju releja $\mu_{R_{start_}}(t)$) i alarma impulsa za isključenje (funkcije pripadnosti stanju isključenja $\mu_{R_{trip_}}(t)$). Treće u nizu je definirano otkazivanje djelovanja releja (nadstrujnog, kratkospojnog i zemljospojnoog) pomoću alarma aktivacije releja (funkcija pripadnosti aktivnom stanju releja $\mu_{R_{start_}}(t)$), ali ne i alarma impulsa za isključenje (funkcija pripadnosti nepostojećem stanju isključenja $\mu_{NoR_{trip_}}(t)$). Otkazivanje djelovanja releja je logička kombinacija poznate i nepoznate informacije kaže kako je došlo do aktivacije releja, ali ne i do slanja signala za isključenje. Četvrto u nizu predstavljeno je ispravno djelovanje prekidača koje se definira pomoću alarma impulsa za isključenje (funkcije pripadnosti stanju isključenja $\mu_{R_{trip_}}(t)$) i alarma otvorenog prekidača (funkcije pripadnosti stanju otvorenog prekidača $\mu_{CB_{open_}}(t)$) što funkcionalno predstavlja uzročno posljedično djelovanje zaštite na prekidač. Peto u nizu na slici 6.52 je prikazano krivo djelovanje prekidača. Krivo djelovanje prekidača se definira pomoću nepostojećeg alarma za isključenje (funkcija pripadnosti nepostojećem stanju isključenja $\mu_{NoR_{trip_}}(t)$) i alarma otvorenog prekidača (funkcije pripadnosti stanju otvorenog prekidača $\mu_{CB_{open_}}(t)$) što znači da se prekidač otvorio sam od sebe bez impulsa za isključenje. Šesto u nizu definirano je otkazivanje djelovanja prekidača koje je opisano kao logička kombinacija alarma za isključenje (funkcije pripadnosti stanju isključenja $\mu_{R_{trip_}}(t)$) i nepojavljivanje alarma otvorenog prekidača (funkcije pripadnosti nepostojećem stanju otvorenog prekidača $\mu_{CB_{close_}}(t)$).



Slika 6.52: Sagitalni dijagram alarma za dalekovod 35 kV

7. REZULTATI

7.1. Slučaj I

Prvi slučaj se odnosi na situaciju kada je nastupio poremećaj u dijelu distributivne mreže, a na KRD-u se pojavljuju alarmi prikazani u tablici 7.1. Dio promatrane mreže na koju se odnose alarmi iz tablice 7.1 prikazan je na slici 6.7. Zanima nas identifikacija kvara, funkcionalno stanje prekidača i releja na tom dijelu distributivne mreže. Tablica 7.1 sadrži tri alarma koji se odnose na stanje prekidača i releja s njihovim pripadnim vremenima. Iz tablice 7.1 se zaključuje gledajući samo stanja releja i prekidača kao uzročno-posljedičnu vezu kako je riječ o djelovanju releja i prekidača.

Tablica 7.1: Alarmi slučaj I

Redni br.	Alarmi	Stanje	Lokacija	Vrijeme
1	Alarm	CBopen	VP35kV	18:36:14.570
2	Alarm	Rtrip_oc	VP35kV	18:36:14.500
3	Alarm	Rstsrt_oc	VP35kV	18:36:12.124

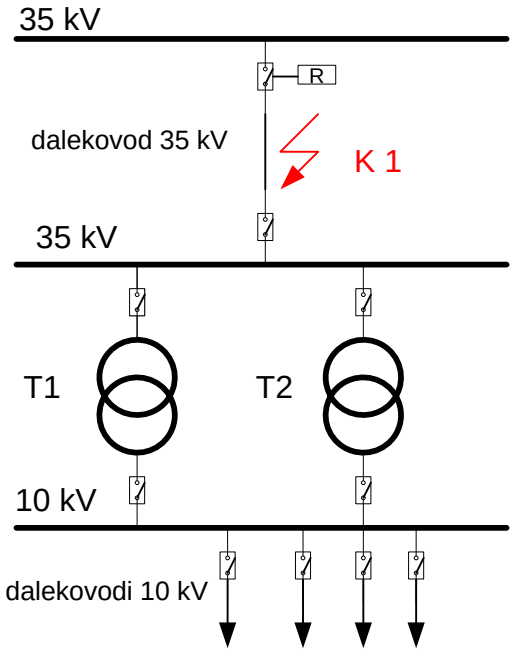
7.1.1. Dijagnoza I

Unosom alarma iz tablice 7.1 u FES dolazi se do dijagnoze djelovanja i identifikacije kvara što se može opširnije vidjeti u dodataku [C]. Iz rezultata koji su prikazani u tablici 7.2 može se zaključiti kako je ispravno djelovanje prekidača na dalekovodu 35 kV kvantificirano s ocijenom pripadnosti 0.8755, a ispravno djelovanje nadstrujnog releja koji štiti dalekovod 35 kV je ocijenjeno s 0.8524.

Tablica 7.2: Dijagnoza I

Dijagnoza	Oznaka	Ocjena pripadnosti
Ispranvno djelovanje prekidača na dalekovodu 35 kV	cbo_35kV	0.8755
Ispravno djelovanje nadstrujnog releja na dalekovodu 35 kV	ro_oc35kV	0.8524
Identifikacija kvara na dalekovodu 35 kV	VP 35 kV	0.7763

Identifikacija kvara na dalekovodu 35 kV je potvrđena i ocjenjena s ocjenom pripadnosti 0.7763 što je prikazano na slici 7.1.



Slika 7.1: Identifikacija kvara za slučaj I

7.2. Slučaj II

Nakon poremećaja u distributivnoj mreži pojavili su se alarmi na KRD-u koji su prikazani na u tablici 7.3. Mreža na koju se odnose ti alarmi prikazana je slikom 6.7. U tablici 7.3 nalaze se tri alarma od kojih se dva odnose na djelovanje releja (Rstart_oc, Rtrip_oc) i jedan na djelovanje prekidača Cbopen. Iz stanja alarma i uzročno-posljedične veze između njih može se zaključiti kako je riječ o nekoj vrsti djelovanja releja i prekidača.

Tablica 7.3: Alarmi na KRD-u nakon poremećaja za slučaj II

Redni br.	Alarmi	Stanje	Lokacija	Vrijeme
1	Alarm	CBopen	VP10kV	15:16:12:930
2	Alarm	Rtrip_oc	VP10kV	15:16:12.880
3	Alarm	Rstsrt_oc	VP10kV	15:16:12.252

Uzročno-posljedična veza se vidi na sagitalnom dijagramu na slici 6.50 za dalekovod 10 kV te može upućivati na ispravano djelovanje nadstrujnog releja, krivo djelovanje nadstrujnog releja i na ispravano djelovanje prekidača dalekovoda 10 kV.

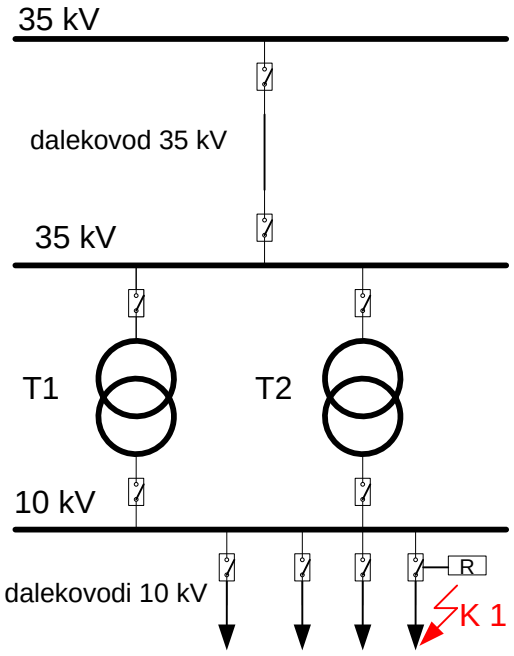
7.2.1. Dijagnoza II

Unosom alarma iz tablice 7.3 u FES može se identificirati kvar i kako je funkcionalno djelovanje releja i prekidača detaljnije pogledati dodatak [C]. Iz tablice 7.4 vidimo kako je riječ o krivom djelovanju nadstrujnog releja s ocjenom pripadnosti od 0.8072, ispravnom djelovanju prekidača dalekovoda 10 kV s ocjenom pripadnosti od 0.8365 i identifikacijom kvara na dalekovodu 10 kV s ocjene pripadnosti 0.7716.

Tablica 7.4: Dijagnoza za slučaj II

Dijagnoza	**Oznaka**	**Ocjena pripadnosti**
Ispravno djelovanje prekidača na dalekovodu 10 kV	cbo_10kV	0.8365
Krivo djelovanje nadstrujnog releja na dalekovodu 10 kV	rfo_oc10kV	0.8072
Identifikacija kvara na dalekovodu 10 kV	VP 10 kV	0.7716

Iznos ocjene pripadnosti od 0.7716 potvrđuje identikikaciju kvara na dalekovodu 10 kV što je i prikazano slikom 7.2.



Slika 7.2: Identifikacija kvara za slučaj II

7.3. Slučaj III

Nakon poremećaja u mreži pojavljuju se alarmi na KRD-u prikazani u tablici 7.5. U tablici 7.5 nalazi se šest alarma od kojih se tri odnosi na dalekovod 35 kV i tri na transformatorsko polje. Iz samih stanja alarma može se zaključiti kako je riječ o djelovanju zaštite i prekidača na VP 35 kV i transformatorskom polju. Nepoznavajući vremena djelovanja releja ne može se ništa više zaključiti o funkcionalnom djelovanju releja i prekidača na VP 35 kV i transformatorskom polju.

Tablica 7.5: Alarmi za slučaj III

Redni br.	Alarmi	Stanje	Lokacija	Vrijeme
1	Alarm	CBopen	VP 35kV	10:23:12.340
2	Alarm	Rtrip_oc	VP 35kV	10:23:12.310
3	Alarm	Cbsopen	TP	10:23:11.545
4	Alarm	Rtrip_oc	TP	10:23:11.520
5	Alarm	Rstart_oc	TP	10:23:10.011
6	Alarm	Rstart_oc	VP 35kV	10:23:10.010

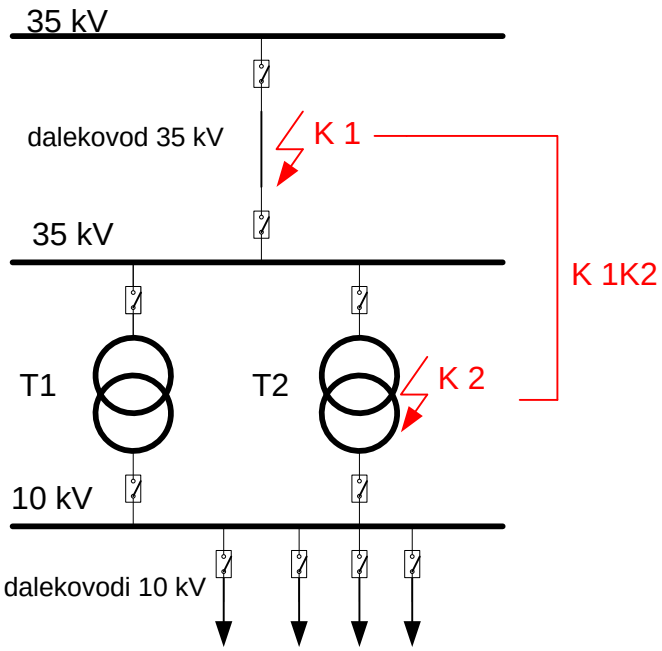
Uzročno-posljedična veza prikazana je na sagitalnim dijagramima. Slika 6.51 odnosi se na transformatorsko polje, a slika 6.52 odnosi se na dalekovodno polje 35 kV.

7.3.1. Dijagnoza III

Nakon unošenja alarma s pripadajućim vremenskim oznakama iz tablice 7.5 u NES prikazano u dodatku [C] dolazi se do dijagnoze čiji su rezultati prikazani u tablici 7.6. Iz tablice 7.6 se vidi kako je identificiran kvar na dalekovodnom polju 35 kV s ocjenom pripadnosti 0.5, transformatorskom polju s ocjenom pripadnosti od 0.5 i simultani kvar na dalekovodnom polju 35 kV i transformatorskom polju koji je kvantificiran s ocjenom pripadnosti od 0.5. U tablici 7.6 nalazi se i dijagnoza ispravnog djelovanja nadstrujnog releja i prekidača na dalekovodnom polju 35 kV sa svojim ocjenama pripadnosti od 1 i 0.9822. Dijagnosticirano je i ispravno djelovanje nadstrujnog releja i oba prekidača na transformatorskom polju s ocjenama pripadnosti od 1 i 0.85. Identificirani kvarovi za slučaj 3 prikazani su na slici 7.3.

Tablica 7.6: Dijagnoza kvara za slučaj III

Dijagnoza	Oznaka	Ocjena pripadnosti
Ispravno djelovanje nadstrujnog releja na dalekovodu 35 kV	ro_oc35kV	1
Ispravno djelovanje nadstrujnog releja na transformatoru	ro_octp	1
Ispravno djelovanje prekidača na dalekovodu 35 kV	cbo_35kV	0.9822
Ispravno djelovanje oba prekidača na transformatoru	cbso_tp	0.85
Identifikacija kvara na dalekovodu 35 kV	VP 35 kV	0.5
Identifikacija kvara na transformatoru	TP	0.5
Identificija simultanog kvar na dalekovodu 35 kV i transformatoru	VP 35 kV i TP	0.5



Slika 7.3: Identifikacija kvarova za slučaj III

7.4. Slučaj IV

Nakon poremećaja u distributivnoj mreži pojavljuje se samo jedan alarm na KRD-u prikazan u tablici 7.7. Alarm se odnosi na otvaranje prekidača na dalekovodnom polju 10 kV. Jedino što se može zaključiti je da se radi o sekciji na kojoj nastupio kvar, ali ne i da li je djelovanje ispravno ili krivo.

Tablica 7.7: Alarmi na KRD-u za slučaj IV

Redni br.	Alarmi	Stanje	Lokacija	Vrijeme
1	Alarm	CBopen	VP10kV	12:43:16.156

Uzročno-posljedična veza se može vidjeti sa sagitalnog dijagram na slici 6.50 iz čega se može pretpostaviti dijagnoza krivog djelovanja prekidača na dalekovodu 10 kV. Promatrana distributivna mreža je prikazana je na slici 6.7.

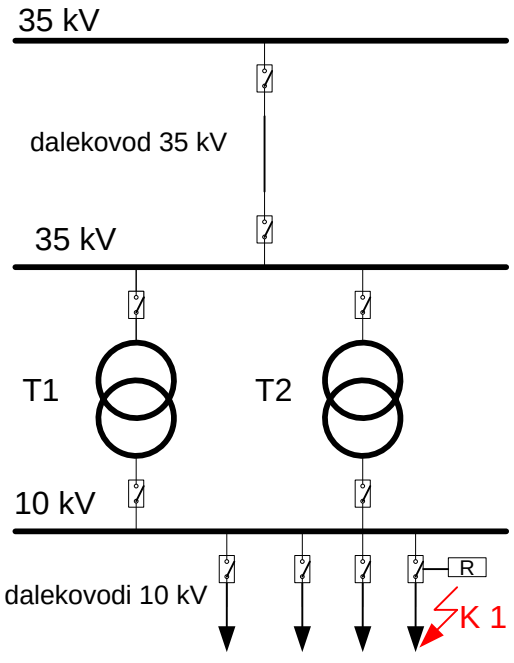
7.4.1. Dijagnoza IV

Unošenjem alarma s pripadajućim stanjem i vremenom u NES prikazano u dodatku [C] dolazi se do rezultata dijagnoze koji su prikazani u tablici 7.8. Iz tablice 7.8 vidimo kako je djagnosticirano krivo djelovanje prekidača na dalekovodu 10 kV s ocjenom pripadnosti od 0.682. Identifikacija kvara je također određena na dalekovodu 10 kV s ocjenom pripadnosti od 0.682. Dijagnoza vezana za krivo djelovanje prekidača donesena je na bazi samo jednog alarma te je iskazana s 68,2 % mogućnosti tog funkcionalnog djelovanja.

Tablica 7.8: Rezultati dijagnoze za slučaj IV

Dijagnoza	Oznaka	Ocjena pripadnosti
Krivo djelovanje prekidača na dalekovodu 10 kV	cbfo_10kV	0.682
Identifikacija kvara na dalekovodu 10 kV	VP 10 kV	0.682

Lokacija kvara i stanje releja prikazani su na slici 7.4.



Slika 7.4: Identifikacija kvara za slučaj IV

7.5. Slučaj V

Nakon poremećaja u distributivnoj mreži pojavio se samo jedan alarm na KRD-u prikazan u tablici 7.9. Alarm se odnosi na aktiviranje kratkospojnog releja koji štiti dalekovodno polje 35 kV. Iz alarma u tablici 7.9 prepoznaje se jedino kako se kvar odnosi na dalekovd 35 kV, ali ne i način djelovanja kratkospojnog releja koji štiti dalekovod 35 kV.

Tablica 7.9: Alarmi koji su se pojavili na KRD-u za slučaj V.

Redni br.	Alarmi	Stanje	Lokacija	Vrijeme
1	Alarm	Rstart_sc	VP35kV	14:23:17.129

Uzročno-posljedična veza djelovanja se vidi na sagitalnom dijagram slika 6.52 koji se odnosi na dalekovod 35 kV. Dijagram upućuje na otkazivanje djelovanja kratkospojne zaštite na dalekovodu 35 kV. Promatrana distributivna mreža je prikazana je na slici 6.7.

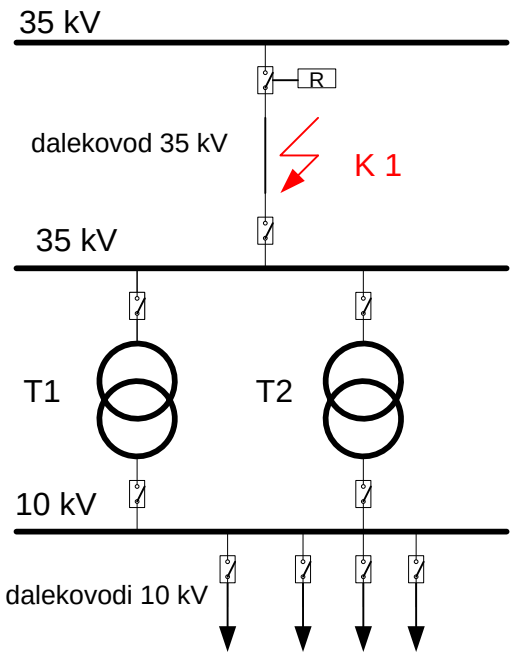
7.5.1. Dijagnoza V

Unošenjem alarma s pripadajućim stanjem i vremenom u NES prikazano u dodatku [C] dolazi se do rezultata dijagnoze koji su prikazani u tablici 7.10. Iz tablice 7.10 vidi se kako je riječ o otkazivanju djelovanja kratkospojnog releja s iznosom funkcije pripadnosti od 0.67. Identificiran je kvar na dalekovodu 35 kV s iznosom ocjene pripadnosti od 0.67. Dijagnoza vezana za otkazivanje djelovanja kratkospojnog releja koji štiti dalekovod 35 kV donesena je na bazi samo jednog alarma te je kvantificirana kao 67 % mogućnost.

Tablica 7.10: Rezultati dijagnoze za slučaj V

Dijagnoza	Oznaka	Ocjena pripadnosti
Otkazivanje rada kratkospojnog releja na dalekovodu 35 kV	rfto_sc35kV	0.67
Identifikacija kvara na dalekovodu 35 kV	VP 35 kV	0.67

Identificirani kvar dobiven u sklopu dijagnoze prikazan je na slici 7.5.



Slika 7.5: Identifikacija kvara za slučaj V

7.6. Slučaj VI

Nakon poremećaja u distributivnoj mreži pojavio se samo jedan alarm na KRD-u prikazan u tablici 7.11. Alarm se odnosi na djelovanje nadstrujnog releja koji štit dalekovodno polje 10 kV. Jedino što se može zaključiti je to kako se kvar odnosi na dalekovod 10 kV. Funkcionalno djelovanje nadstrujnog releja iz ovog alarma se ne može dijegnosticirati.

Tablica 7.11: Alarmi na KRD-u za slučaj VI

Redni br.	Alarmi	Stanje	Lokacija	Vrijeme
1	Alarm	Rtrip_oc	VP10kV	22:25:28.124

Uzročno-posljedična veza se vidi na sagitalnom dijagram slika 6.50 koji se odnosi na dalekovod 10 kV. Može se pretpostaviti otkazivanje djelovanja prekidača na dalekovodu 10 kV. Promatrana distributivna mreža je prikazana je na slici 6.7.

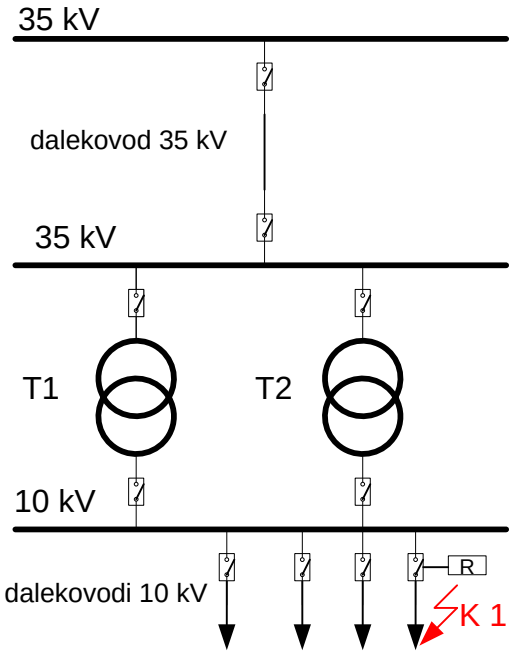
7.6.1. Dijagnoza VI

Unosom alarma s pripadajućim stanjem i vremenom u NES dodatak [C] dolazi se do rezultata dijagnoze koji su prikazani u tablici 7.12. Dijagnosticirano je otkazivanje djelovanja prekidača na dalekovodu 10 kV s iznosom ocjene pripadnosti od 0.218. Identificiran je kvar na dalekovodu 10 kV s ocejnom pripadnosti 0.218. Dijagnoza je donesena na bazi samo jednog alarma i ocjenjena s mogučnošću od 21.8 %.

Tablica 7.12: Rezultati dijagnoze za slučaj VI

Dijagnoza	**Oznaka**	**Ocjena pripadnosti**
Otkazivanje rada prekidača na dalekovodu 10 kV	cbfto_10kV	0.218
Identificirani kvar na dalekovodu 10 kV	VP 10 kV	0.218

Identificirani kvar dobiven u sklopu dijagnoze prikazan je na slici 7.6.



Slika 7.6: Identificirani kvar za slučaj VI

7.7. Slučaj VII

Nakon pojave poremećaja u distributivnoj mreži pojavljuju se alarmi na KRD-u koji su prikazani u tablici 7.13. U tablici 7.13 nalazi se pet alarma od kojih se dva odnose na dalekovod 35 kV, dva na dalekovod 10 kV i jedan na transformatorsko polje. Djelovanje nadstrujnog releja koji štiti dalekovod 35 kV se vidi iz statusa alarma. Djelovanje nadstrujnog releja i pripadajućeg prekidača se vidi iz statusa (alarma) za dalekovod 10 kV. Otvorenost oba prekidača su prikazana statusom pripadnog alarma.

Tablica 7.13: Alarmi prikazani na KRD-u za slučaj VII

Redni br.	Alarmi	Status	Lokacija	Vrijeme
1	Alarm	Rtrip_oc	VP 35 kV	18:23:17:000
2	Alarm	CBsopen	TP	18:23:17.000
3	Alarm	Cbopen	VP 10 kV	18:23:16.450
4	Alarm	Rtrip_oc	VP 10 kV	18:23:16.432
5	Alarm	Rstart_oc	VP 35kV	18:23:15.426

Iz sagitalnih dijagrama se može jednostavno zaključiti o kojoj je dijagnozi riječ, ako imamo statuse alarma na raspolaganju slika 6.50, 6.51 i 6.52. Distributivna mreža koju promatramo nalazi se na slici 6.7.

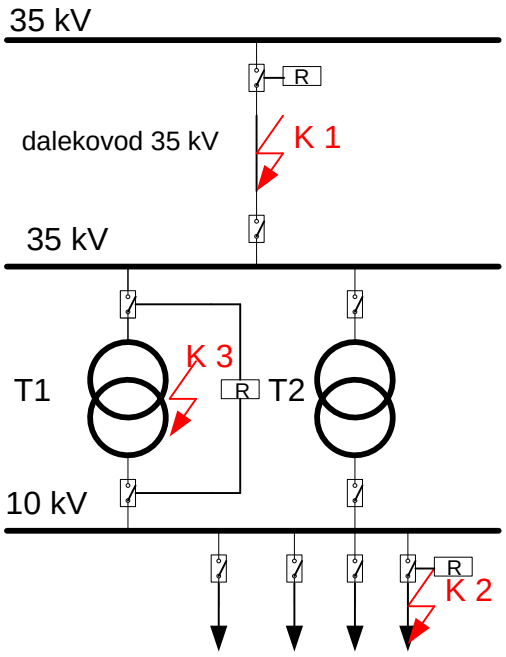
7.7.1. Dijgnoza VII

Unosom statusa alarma i pripadajućih vremena u NES dolazi se do dijagnoze kvara što je prikazano u dodatku [C]. Rezultati dijagnoze za slučaj 7 prikazani su tablicom 7.14. Identificiran je kvar na dalekovodu 35 kV s ocjenom pripadnosti od 0.8601, kvar na dalekovodu 10 kV s iznosom funkcije pripadnosti 0.78 i kvar na transformatoru s ocjenom pripadnosti od 0.704. Dijagnosticirano je ispravano djelovanje nadstrujne zaštite koja štiti dalekovod 35 kV s ocjenom pripadnosti od 0.8601 i ispravano djelovanje prekidača na dalekovodu 10 kV s ocjenom pripadnosti 0.78. Ustanovljeno je i krivo djelovanje oba prekidača koji štite transformator s ocjenom pripadnosti od 0.704.

Tablica 7.14: Rezultati dijagnoze za slučaj VII

Dijagnoza	Oznaka	Ocjena pripadnosti
Ispravno djelovanje nadstrujnog releja na dalekovodu 35 kV	ro_oc35kV	0.8601
Identificiran je kvar dalekovodu 35 kV	VP 35 kV	0.8601
Ispravno djelovanje prekidača na dalekovodu 10 kV	cbo_10kV	0.78
Identificiran je kvar na dalekovodu 10 kV	VP 10 kV	0.78
Krivi djelovanje oba prekidača na transformatoru	cbsfo_tr	0.74
Identificiran je kvar na transformatoru	TP	0.74

Identificirani kvarovi dobiveni u dijagnozi nalaze se prikazani na slici 7.7.



Slika 7.7: Identificirani kvarovi u slučaj VII

7.8. Slučaj VIII

Događaj dana 10.02.2010. godine na distributivnoj mreži izazivao je listu alarma koji su prikazani slikom 7.8. TS 35/10 kV Istok ima mogućnost napajanja iz TS 110/35 kV Osijek 1 i TS 35/10 kV Šećerana te zajedno predstavljaju dio distributivne mreže u nadležnosti Elektroslavonije Osijek slika 6.7. U trenutku poremećaja TS 35/10 kV Istok napajana je iz TS 110/35 kV Osijek 1. Treba izvršiti dijagnozu kvara kako bi se što prije mreža vratila u prvobitno stanje te bi time što manji broj kupaca ostao bez napona. Alarmi se pojavljuju na KRD-u, a alarm koji se dogodio zadnji potiskuje ostale alarme prema dolje, što znači kako je najgornji alarm stigao posljednji. Kod dijagnoze se alarmi promatraju odozdo prema gore, jer najdoljni alarm je prvi koji se pojavio na KRD-u. Analizirajmo alarme koji se nalaze na slici 7.8. Zelenom bojom su označeni alarmi koji su se pojavili kao rezultat djelovanja sustava zaštite nakon poremećaja nastalog u distributivnoj mreži. Ostali alarmi su se pojavili nakon djelovanja operatera koji pokušava dovesti distributivnu mrežu u početno stanje. Taj dio detaljno je objašnjen u [188, 189] te je manje bitan za našu buduću dijagnozu. Vidimo kako je riječ o dvije skupine alarma označenih zelenom bojom gdje se jedna nalazi na dnu, a druga pri vrhu. Ako bolje pogledamo to su isti alarmi samo što su alarmi na dnu nastali kao rezultat prvobitnog poremećaja, a alarmi na vrhu kao rezultat manipulacije operatera te ih možemo smatrati manje važnima za dijagnozu. Fokusiramo se na donju skupinu zeleno označenih alarma koji su izvorna posljedica događaja u mreži. Među njima ima alarma koji nisu bitni u dijagnozi (samo alarmi koji se odnose na statuse releja i prekidača) te njih također treba zanemariti. Samo su četiri alarma bitina za dijagnozu iz tolikog broja alarma. Od toga su dva alarma povezana s vodnim poljem 10 kV i dva s VP 35 kV. Alarmi koji se odnose na VP 10 kV su isključenje kratkospojne zaštite (Rtrip_sc) i isključenje prekidača na VP 10 kV (Cbopen_10kV). Alarmi vezani za vodno polje 35 kV također su isključenje kratkospojne zaštite (Rtrip_sc) i otvaranje prekidača na istoimenom VP 35 kV (Cbopen_35 kV).

11.2.2010	08:19:34.807	ISTOK	10	108/208	RAST UZEM	Međupoložaj 00
11.2.2010	08:19:34.344	ISTOK	10	108/208	RAST VOD	ISKLJUCEN
11.2.2010	08:19:34.340	ISTOK	10	108/208	RAST VOD	Stanje kvara 11
11.2.2010	08:17:55.594	ISTOK	10	108/208	RAST S 1	ISKLJUCEN
11.2.2010	08:17:55.564	ISTOK	10	108/208	RAST S 1	Međupoložaj 00
10.2.2010	21:30:25.818	ISTOK	10	TUFEK	PREKIDAC	UKLJUCEN
10.2.2010	21:30:25.815	ISTOK	10	TUFEK	PREKIDAC	Stanje kvara 11
10.2.2010	21:29:57.064	ISTOK	10	KTS 180	PREKIDAC	UKLJUCEN
10.2.2010	21:29:57.055	ISTOK	10	KTS 180	PREKIDAC	Stanje kvara 11
10.2.2010	21:29:25.577	ISTOK	10	KTS 265	PREKIDAC	UKLJUCEN
10.2.2010	21:29:25.570	ISTOK	10	KTS 265	PREKIDAC	Međupoložaj 00
10.2.2010	21:29:11.299	ISTOK	NAPON AC NA SABIRNICAMA			POVRATAK
10.2.2010	21:28:53.429	ISTOK	35	ZDV OS 1	PREKIDAC	UKLJUCEN
10.2.2010	21:28:53.426	ISTOK	35	ZDV OS 1	PREKIDAC	Međupoložaj 00
10.2.2010	21:28:20.208	OSK 1	35	ISTOK	PREKIDAC	UKLJUCEN
10.2.2010	21:28:20.195	OSK 1	35	ISTOK	PREKIDAC	Stanje kvara 11
10.2.2010	21:27:48.387	ISTOK	10	TUFEK	PREKIDAC	ISKLJUCEN
10.2.2010	21:27:48.378	ISTOK	10	TUFEK	PREKIDAC	Stanje kvara 11
10.2.2010	21:27:33.912	ISTOK	10	KTS 180	PREKIDAC	ISKLJUCEN
10.2.2010	21:27:33.907	ISTOK	10	KTS 180	PREKIDAC	Stanje kvara 11
10.2.2010	21:27:17.159	ISTOK	10	KTS 265	PREKIDAC	ISKLJUCEN
10.2.2010	21:26:41.017	ISTOK	35	ZDV OS 1	PREKIDAC	ISKLJUCEN
10.2.2010	21:26:15.915	OSK 1	35	APU DEF		PRESTANAK
10.2.2010	21:26:15.906	OSK 1	35	Z. KRATKOSPOJNA		PRESTANAK
10.2.2010	21:26:15.902	OSK 1	ISPRAVLJAC AC/DC 220V			POVRATAK
10.2.2010	21:26:15.803	OSK 1	35	ISTOK	PREKIDAC	ISKLJUCEN
10.2.2010	21:26:15.791	OSK 1	35	ISTOK	PREKIDAC	Stanje kvara 11
10.2.2010	21:26:15.754	OSK 1	35	APU DEF		UPOZ
10.2.2010	21:26:15.743	OSK 1	35	Z. KRATKOSPOJNA		ISK
10.2.2010	21:26:15.646	OSK 1	ISPRAVLJAC AC/DC 220V			ISPAD
10.2.2010	21:26:15.527	ISTOK	10	Z. KRATKOSPOJNA		PRESTANAK
10.2.2010	21:26:15.512	ISTOK	NAPON AC NA SABIRNICAMA			NESTANAK
10.2.2010	21:26:15.492	ISTOK	10	108/208	PREKIDAC	ISKLJUCEN
10.2.2010	21:26:15.488	ISTOK	10	108/208	PREKIDAC	Međupoložaj 00
10.2.2010	21:26:15.444	ISTOK	10	Z. KRATKOSPOJNA		ISK
10.2.2010	21:26:15.426	ISTOK	10	108/208	PREKIDAC	UKLJUCEN
10.2.2010	21:26:15.420	ISTOK	10	108/208	PREKIDAC	Međupoložaj 00
10.2.2010	21:25:42.409	ISTOK	35	KDV SEC	PREKIDAC	ISKLJUCEN
10.2.2010	21:25:42.406	ISTOK	35	KDV SEC	PREKIDAC	Stanje kvara 11
10.2.2010	21:25:03.902	ISTOK	35	ZDV OS 1	PREKIDAC	UKLJUCEN
10.2.2010	21:25:03.899	ISTOK	35	ZDV OS 1	PREKIDAC	Međupoložaj 00
10.2.2010	21:24:19.626	ISTOK	35	ZDV OS 1	RAST S 1	UKLJUCEN
10.2.2010	21:24:19.172	ISTOK	35	ZDV OS 1	RAST S 1	Stanje kvara 11
10.2.2010	21:14:42.755	OSK 1	35	ISTOK	PREKIDAC	UKLJUCEN
10.2.2010	21:14:42.743	OSK 1	35	ISTOK	PREKIDAC	Stanje kvara 11
10.2.2010	20:56:06.724	ISTOK	10	TUFEK	PREKIDAC	UKLJUCEN
10.2.2010	20:56:06.721	ISTOK	10	TUFEK	PREKIDAC	Stanje kvara 11
10.2.2010	20:55:38.458	ISTOK	10	KTS 180	PREKIDAC	UKLJUCEN
10.2.2010	20:55:38.456	ISTOK	10	KTS 180	PREKIDAC	Stanje kvara 11
10.2.2010	20:54:45.668	ISTOK	10	KTS 265	PREKIDAC	UKLJUCEN
10.2.2010	20:54:45.661	ISTOK	10	KTS 265	PREKIDAC	Međupoložaj 00
10.2.2010	20:54:23.789	ISTOK	10	TP 2	PREKIDAC	UKLJUCEN
10.2.2010	20:54:23.785	ISTOK	10	TP 2	PREKIDAC	Međupoložaj 00
10.2.2010	20:54:15.927	ISTOK	NAPON AC NA SABIRNICAMA			POVRATAK

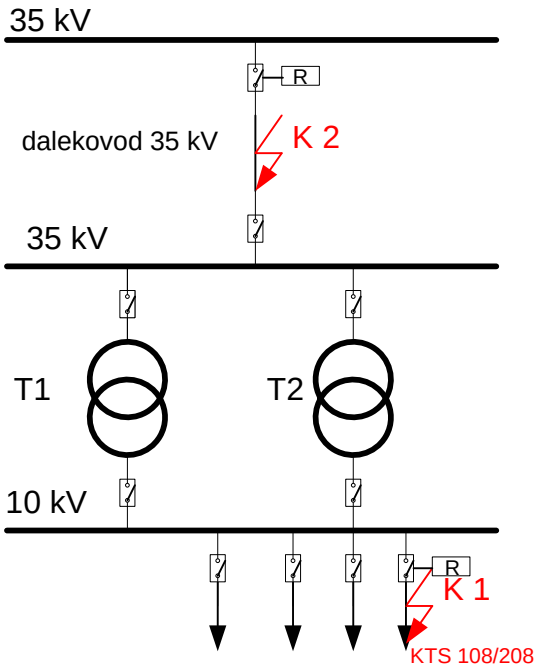
10.2.2010	20:53:56.047	ISTOK	10	TP 1	PREKIDAC	UKLJUCEN
10.2.2010	20:53:56.038	ISTOK	10	TP 1	PREKIDAC	Stanje kvara 11
10.2.2010	20:53:32.875	ISTOK	10	KTS 265	PREKIDAC	ISKLJUCEN
10.2.2010	20:53:32.875	ISTOK	10	KTS 265	PREKIDAC	Stanje kvara 11
10.2.2010	20:53:30.055	ISTOK	35	TP 2	PREKIDAC	UKLJUCEN
10.2.2010	20:53:30.055	ISTOK	35	TP 2	PREKIDAC	Međupoložaj 00
10.2.2010	20:53:15.660	ISTOK	35	TP 1	PREKIDAC	UKLJUCEN
10.2.2010	20:53:15.646	ISTOK	35	TP 1	PREKIDAC	Međupoložaj 00
10.2.2010	20:52:43.043	ISTOK	10	KTS 180	PREKIDAC	ISKLJUCEN
10.2.2010	20:52:43.028	ISTOK	10	KTS 180	PREKIDAC	Stanje kvara 11
10.2.2010	20:52:24.778	ISTOK	35	KDV SEC	PREKIDAC	UKLJUCEN
10.2.2010	20:52:24.775	ISTOK	35	KDV SEC	PREKIDAC	Međupoložaj 00
10.2.2010	20:52:11.265	ISTOK	10	TUFEK	PREKIDAC	ISKLJUCEN
10.2.2010	20:52:11.256	ISTOK	10	TUFEK	PREKIDAC	Stanje kvara 11
10.2.2010	20:51:58.577	ISTOK	35	TP 1	PREKIDAC	ISKLJUCEN
10.2.2010	20:51:58.566	ISTOK	35	TP 1	PREKIDAC	Međupoložaj 00
10.2.2010	20:51:32.616	ISTOK	10	TP 1	PREKIDAC	ISKLJUCEN
10.2.2010	20:51:16.291	ISTOK	35	TP 2	PREKIDAC	ISKLJUCEN
10.2.2010	20:51:16.283	ISTOK	35	TP 2	PREKIDAC	Međupoložaj 00
10.2.2010	20:50:54.248	ISTOK	10	TP 2	PREKIDAC	ISKLJUCEN
10.2.2010	20:50:54.242	ISTOK	10	TP 2	PREKIDAC	Stanje kvara 11
10.2.2010	20:50:41.470	ISTOK	35	ZDV OS 1	RAST S 1	ISKLJUCEN
10.2.2010	20:50:41.092	ISTOK	35	ZDV OS 1	RAST S 1	Stanje kvara 11
10.2.2010	20:50:21.191	ISTOK	35	ZDV OS 1	PREKIDAC	ISKLJUCEN
10.2.2010	20:50:21.189	ISTOK	35	ZDV OS 1	PREKIDAC	Međupoložaj 00
10.2.2010	20:49:15.379	OSK 1	35	APU DEF		PRESTANAK
10.2.2010	20:49:15.371	OSK 1	35	Z. KRATKOSPOJNA		PRESTANAK
10.2.2010	20:49:15.266	OSK 1	35	ISTOK	PREKIDAC	ISKLJUCEN
10.2.2010	20:49:15.255	OSK 1	35	ISTOK	PREKIDAC	Stanje kvara 11
10.2.2010	20:49:15.217	OSK 1	35	APU DEF		UPOZ
10.2.2010	20:49:15.206	OSK 1	35	Z. KRATKOSPOJNA		ISK
10.2.2010	20:49:15.111	OSK 1	ISPRAVLJAC AC/DC 220V			ISPAD
10.2.2010	20:49:14.984	ISTOK	10	Z. KRATKOSPOJNA		PRESTANAK
10.2.2010	20:49:14.948	ISTOK	10	108/208	PREKIDAC	ISKLJUCEN
10.2.2010	20:49:14.939	ISTOK	NAPON AC NA SABIRNICAMA			NESTANAK
10.2.2010	20:49:14.939	ISTOK	10	108/208	PREKIDAC	Međupoložaj 00
10.2.2010	20:49:14.901	ISTOK	10	Z. KRATKOSPOJNA		ISK

Slika 7.8: Alarmi s KRD-a za slučaj VIII

7.8.1. Dijagnoza VIII

Imajući u vidu kako se radi o četiri bitna alarma iz cijelog niza alarma, a to su alarmi vezani za dalekovod 10 kV („10 z. kratkospojna isk“, "10 108/208 prekidač isključenje ") te alarmi vezani za 35 kV dalekovod („35 z. kratkospojna isk“, „35 Istok prekidač isključen“). Unosom tih alarma u FES i pripadajućih njihovih vremena prikazano je u dodatku [C] dolazi se do rezultata dijagnoze koji su prikazani u tablici 7.15. Iz tablice 7.15 vidi se kako je dijagnosticirano ispravano djelovanje prekidača na VP 10 kV-KTS 108/208 s ocjenom

pripadnosti od 0.8879, a ispravano djelovanje prekidača na VP 35 kV je ocjena pripadnosti 0.6796. Identificiran je kvar na dalekovodnom polju 10 kV (KTS 108/208) s ocjenom pripadnosti od 0.8879 i kvar na dalekovodu 35 kV s ocjenom pripadnosti od 0.6796. U konačnici kako bi se odlučili o kojoj se dionici točno radi koristimo izbor pomoću maksimuma (engl. maximum selection) te se dionica u kvaru za date alarme nalazi na VP 10 kV-KTS 108/208. Moguće dionice u kvaru prikazuje slika 7.9.



Slika 7.9: Identificirani kvarovi na distribucijskoj mreži za slučaj VIII

Tablica 7.15: Rezultati dijagnoze kod slučaja VIII

Dijagnoza	Oznaka	Ocjena pripadnosti
Ispravano djelovanje prekidača na dalekovodu 10 kV	cbo_sc10kV	0.8879
Identificiran kvar na dalekovod 10 kV	VP 10 kV-KTS 108/208	0.8879
Ispravno djelovanje prekidača na dalekovodu 35 kV	cbo_sc35kV	0.6796
Identificiran kvar na dalekovodu 35 kV	VP 35 kV	0.6796

8. ZAKLJUČAK

Sve veće i složenije distributivne mreže prilikom parcijalnih raspada stavljaju operatere u vrlo zahtjevne situacije koje nadilaze njihove mogućnosti u pravovremenoj obradi lavine alarma. Alarmi identificiraju vrlo brze promjene u elektroenergetskom sustavu koje dolaze s različitih lokacija u dispečerski centar. Svi ti alarmi prikazani su na KRD-u složeni kronološkim redom. Osim enormnog broja alarma operateri su suočeni s nedostatkom pojedinih alarma, alarmima koji nisu povezani sa sustavom zaštite, vremenskim kašnjenjem i nepotrebnim alarmima. Kako bi se svi ti problemi riješili razvili su se procesori alarma. Procesori alarma vrše predprocesiranje i procesiranje alarma te prikazuju sažet dijagnostički oblik razumljiv čovjeku. U predprocesiranju se vrši filtracija nepotrebnih alarma dok se ostali problemi rješavaju kod same obrade i donošenja zaključaka. Razvoj procesora alarma odvija se u dva stupnja. U prvom stupnju se razvija off-line sustav za dijagnozu (Tip 1), a u drugom se stupnju tek pristupa razvoju on-line sustava (Tip 2 ili procesor alarma). Ova disertacija se bavi razvojem off-line sustava za dijagnozu kvara na bazi funkcionalnog i strukturalnog djelovanja releja i prekidača. Funkcionalno djelovanje releja i prekidača prikazano je kao logički odnos funkcija pripadnosti određenom stanju releja i prekidača. Razvijeni dijagnostički sustav je zapravo neizraziti ekspertni sustav (model koristi neizrazitu logiku i ekspertne sustave), a za ulazne informacije se koriste statusi releja i prekidača te njihove vremenske oznake. Kako bi se kvantificiralo djelovanje, krivo djelovanje i otkazivanje djelovanja releja i prekidača do izražaja dolazi vremenska oznaka alarma. Određivanje među djelovanja (krivog djelovanja releja i prekidača) nije moguće odrediti bez vremenske oznake alarma. Bez vremenske oznake alarma nije moguće kvantificirat identificirani kvar. Za dijagnozu bilo kojeg funkcionalnog djelovanja releja i prekidača potrebna su minimalno dva stanja (alarma) s pripadajućim vremenskim oznakama. Situacije u kojima se dijagnoza djelovanja bazira na samo jednom stanju (alarmu) nadopunjuje se modelom za nepostojeću informaciju. Kako bi se mogla donijeti dijagnoza u logički odnos se stavlja poznato stanje i nepostojeća informacija. U disertaciji se problem nepostojeće informacije modelira pomoću neizrazite logike s funkcijom pripadnosti u obliku linearnog pravca u odnosu na vrijeme što znači kako se pripadnost skupu nepostojeće informacije povećava prolaskom vremena. U neizrazitoj logici se identifikacija kvara definira kao unija između skupa releja koji su djelovali i prekidača koji su isključili. U ovoj disertaciji se koristi hibridni operator unije koji je iskazan u obliku aritmetičke sredine Hamackerovog i Schweizerovog operatora. Hibridni operator unije ima ulogu kvantificiranja identificiranog kvara. Uspješnost off-line sustava za

dijagnozu prikazana je u disertaciji na osam slučaja. Rezultati prvog slučaja na bazi dostupnih alarma dijagnosticiraju i kvantificiraju ispravno djelovanje nadstrujnog releja koji štit dalekovod 35 kV i ispravno djelovanje pripadajućeg prekidača 35 kV dalekovoda s visokom ocjenom pripadnosti. Kvantifikacija samog kvara nešto je niža u odnosu na kvantificirane vrijednosti nadstrujnog releja koji štiti dalekovod i pripadajućeg prekidača, no i dalje nedvojbeno potvrđuje kako je identificiran kvar na dalekovodu 35 kV. Rezultati drugog slučaja utvrđuju krivo djelovanje nadstrujnog releja koji štiti dalekovod 10 kV i pripadajućeg prekidača što potvrđuje visoka ocjena pripadnosti. Identificirani kvar na dalekovodu 10 kV također je potvrđen i ocjenjen visokom ocjenom pripadnosti. Rezultati trećeg slučaja utvrđuju ispravno djelovanje nadstrujnog releja koji štiti dalekovod 35 kV i pripadajućeg prekidača što i potvrđuje ocjena pripadnosti koja je blizu idealne. Visoka ocjena pripadnosti dijagnoza dodijeljena je i ispravnom djelovanju nadstrujne zaštite koja štiti transformator i ispravnom djelovanju pripadajućeg para prekidača. Kod identifikacije kvara na dalekovodu 35 kV i transformatoru ocjene pripadnosti su kontradiktorne očekivanim (cca. 50% manje). Slučaj pet potvrđuje dijagnozu krivog djelovanja prekidača na dalekovodu 10 kV na bazi samo jednog poznatog alarma, a to je otvoren prekidač 10 kV dalekovoda. Ocjena pripadnosti skupu je visoka. U petom slučaju je dijagnosticirano otkazivanje rada kratkospojnog releja na dalekovodu 35 kV, a ocjena pripadnosti toj dijagnozi je blizu 70%. Dijagnoza u slučaju 5 postavljena je na bazi jednog poznatog alarma i nepostojeće informacije. Rezultati u šestom slučaju dijagnosticirali su otkazivanje djelovanja prekidača na dalekovodu 10 kV s niskom ocjenom pripadnosti. Rezultati sustava za dijagnozu za sedmi slučaj potvrđuju identifikaciju kvara na tri različite sekcije s visokim ocjenama pripadnosti. Dijagnosticirano je ispravno djelovanje nadstrujnog releja na dalekovodu 35 kV, ispravno djelovanje prekidača na dalekovodu 10 kV i krivo djelovanje oba prekidača na transformatoru. Rezultati osmog slučaja se odnose na stvarnu situaciju parcijalnog raspada dijela distributivne mreže distribucijskog područja "Elektroslavonije Osijek" gdje je sustav za dijagnozu utvrdio ispravno djelovanje prekidača na dalekovodu 10 kV (KTS 108/208) i dalekovodu 35 kV. Na bazi alarma dostupnih ovoj situaciji nije moguće dijagnosticirati bilo kakvo djelovanje releja. Iznosi kvantificiranosti pojedinih dijagnoza pokazuju kako je veća mogućnost kvara na dalekovodu 10 kV (KTS 108/208) nego na dalekovodu 35 kV. Razlozi niskih ocjena pripadnosti kod trećeg slučaja su vezani za jednostruke kvarove i simultani kvar zbog hibridnog operatora unije. Izbor hibridnog operatora unije u obliku aritmetičke sredine Hamackerovog i Schweizerovog operatora unije za kvantificiranje identificiranog kvara ne daje očekivane rezultate kada su kvantificirana djelovanja releja i prekidača blizu idealnih

vrijednosti. Manjim odmakom od idealnih vrijednosti hibridni operator daje zadovoljavajuće rezultate. Dijagnoze za slučajeve četiri, pet i šest su utvrđene i kvantificirane na bazi samo jednog poznatog alarma (stanja) i nepoznate informacije. Kvantificiranosti dijagnoza u slučajevima četiri i pet su približno jednake, dok je slučaj šest ocijenjen izrazito manjom vrijednošću. Razlozi takvih ocjena u slučajevima četiri, pet i šest su zbog što dijagnoze ovisi o modelu nepostojeće informacije, načinu njene defuzifikacije i trenutku poznatog alarma (stanja). Također kod dijagnoza u slučajevima četiri i pet na iznos kvantificiranosti utječu poznati alarmi (stanja) za komponente koje dijagnosticiramo. Rezultat tako niske kvantificiranosti u slučaju 6 je zbog toga što se za dijagnozu prekidača koristi poznata informacija (alarm, stanje) pripadnog releja. Kod budućih razmatranja ove problematike, ako se zadržavamo na off-line razini razvoj bi se kretao u smjeru upotpunjavanja dijagnoze s drugim vrstama informacija (napon i struja) te kao što trendovi pokazuju korištenjem sve više neelektričnih veličina u samoj dijagnozi.

9. LITERATURA

[1]. Fukui C., Kawakami J., An expert system for fault section estimation using information from protective relays and circuit breakers, IEEE Transactions on power delivery, Vol. 1, No. 4, pp. 83-90, 1986.

[2]. Lee H. J., Ahn B. S., Park Y. M., A fault diagnosis expert system for distribution substations, IEEE Transactions on power delivery, Vol. 15, No. 1, pp. 92-97, 2000.

[3]. Girgis A. A., Johns M. B., A hybrid expert system for fault section identification, fault type classification and selection of fault location algorithms, IEEE Transactions on power delivery, Vol. 4, No. 2, pp. 978-985, 1989.

[4]. Cardozo E., Talkudar S. N., A distributed expert system for fault diagnosis, IEEE Transactions on power systems, Vol. 3, No. 2, pp. 641-645, 1988.

[5]. Jadid S. B., Jeyasurya B., Khaparde S. A., Power system fault diagnosis expert system using prolog, IEEE Transactions on power delivery, Vol. 4, No. 2, pp. 778-781, 1989.

[6]. Yongli Z., Yang Y. H., Hogg B. W., Zhang W. Q., Gao S., An expert system for power system fault analysis, IEEE Transactions on power systems, Vol. 9, No. 1, pp. 503-509, 1994.

[7]. Vazquez M. E., Oscar L., Chacon M., Hector J., Altuve F., An on-line expert system for fault section diagnosis in power systems, IEEE Transactions on power systems, Vol. 12, No. 1, pp. 357-362, 1997.

[8]. Huang Y. C., Fault section estimation in power systems usisn a novel decision support system, IEEE Transactions on power systems, Vol. 17, No. 2, pp. 439-444, 2002.

[9]. Kezunović M., Spasojević P., Fromen C. W., Sevcik D. R., An expert system for transmission substation event analysis, IEEE Transactions on power delivery, Vol. 8, No. 4, pp. 1942-1949, 1993.

[10]. Kezunović M., Luo X., An expert system for diagnosis of digital relay operation, Project T-17.

[11]. Khedher M. Z., Fuzzy logic in power engineering, Jordan University.

[12]. Kyriakides E., Stahlhut J. W., Heydt G., A next generation alarm processing algorithm incorporating recommendations and decision on wide area control, IEEE Power engineering society general meeting, 2007.

[13]. Lee J. W., Kim J. T., Park J. C., Hwang I. K., Lyu S. P., Computer-based alarm processing and presentation methods in nuclear power plants, World academy of science, engineering and technology, 2010.

[14]. Sauve J. P., at al., Maintenance techniques for intelligent alarm processing system, CRL Publishing, Knowledge engineering, Vol. 13, No. 4, 2005.

[15]. Enns M., at al., Potential applications of expert systems to power system protection, IEEE Transactions on power delivery, Vol. 9, No. 2, pp. 720-728, 1994.

[16]. Kimura T., Nishimatsu S., Ueki Y., Fukuyama Y., Development of an expert system for estimating fault section in control center based on protective system simulation, IEEE Transactions on power delivery, Vol. 7, No. 1, pp. 167-172, 1992.

[17]. Protopapas C. A., Psaltiras K. P., Machias A. V., An expert system for substation fault diagnosis and alarm processing, IEEE Transactions on power delivery, Vol. 6, No. 2, pp. 648-655, 1991.

[18]. Tomsovic K., Liu C. C., Ackerman P., Pope S., An expert system as dispatchers aid for the isolation of line section faults, IEEE Power engineering review, Vol. 7, No. 7, pp. 51-52, 1987.

[19]. Edetrom F., Soder L., On uncontrolled system separation in power system restoration, North American power symposium, pp. 1-7, 2011.

[20]. Subudhi B., Swain A. K., An expert system approach for fault diagnosis in a sub-system of power plant, Indian journal of power & river valley development, pp. 1-3, 1996.

[21]. Tomsovic K., Liu C. C., Ackerman P., Pope S., An expert system as dispatchers aid for the isolation of line section faults, IEEE Transactions on power delivery , Vol. 2, No. 3, pp. 736-743, 1987.

[22]. King P. J. H., Decision tabels, pp. 135-142, 1967.

[23]. Kowalski R. A., The early years of logic programming, Communications of the ACM, Vol. 31, pp. 38-43, 1988.

[24]. Faria L., Silva A., Vale Z., Marques A., Training control centers operators in incident diagnosis and power restoration using intelligent tutoring systems, IEEE Transaction on learning technologies, Vol. 2, No. 2, pp. 135-147, 2009.

[25]. Araya A., Kumar Y., A comparative survey of fault section estimation methods in electric distribution systems, Fifteenth national power systems conference, pp. 154-154-158, Bombay, 2008.

[26]. Jenkins L., Khincha H. P., Shivakumart S., Dash P. K., An application of functional dependencies to the topological alalysis of protection schems, IEEE Transactions on power delivery , Vol. 7, No. 1, pp. 77-83, 1992.

[27]. Liacco T. E., Kraynak T. J., Processing by logic programming of circuit-breaker and protective-relaying information, IEEE Transactions on power apparatus and systems , Vol. 88, No. 2, pp. 171-175, 1969.

[28]. Talkudar S. N., Cardozo E., Leao L. V., Toast: The power system operator's assistant, IEEE Computer magazines, Vol. 19, No. 7, pp. 53-60, 1986.

[29]. Talkudar S. N., Cardozo E., Perry T., The operator's assistant—an intelligent, expandable program for power system trouble analysis, IEEE Transactions on power systems, Vol. 1, No. 3, pp. 182-187, 1986.

[30]. Jeyasurya B., Venkata S. S., Vadari S. V., Postforoosh J., Fault diagnosis using substation computer, IEEE Transactions on power delivery , Vol. 5, No. 2, pp. 1195-1201, 1990.

[31]. Kirschen D. S., Wollenberg B. F., Irisarri G. D., Bann J. J., Miller B. N., Controlling power systems during emergencies: The role of expert systems, IEEE Computer applications in power systems, Vol. 2, No. 2, pp. 41-45, 1989.

[32]. Barnett C. W., at al., Summary of the special publication "Application of fault and disturbance recording devices for protective system analysiy, IEEE Transactions on power delivery , Vol. 4, No. 3, pp. 1625-1630, 1989.

[33]. Balakrishnan R., Pahwa A., A computer assisted intelligent storm outage evaluator for power distribution systems, IEEE Transactions on power delivery , Vol. 5, No. 3, pp. 1591-1597, 1990.

[34]. Hsu Y. Y., at al., An expert system for locating distribution system faults, IEEE Transactions on power delivery , Vol. 6, No. 1, pp. 366-372, 1991.

[35]. Marathe H. Y., Liu C. C., Tsai M S., Rogers R. G., Maurer J. M., An on-line operational expert system with data validation capabilities, Power industry computer application conference, pp. 56-63, PICA, 1989.

[36]. Keronen J. J., An expert system prototype for event diagnosis and real-time operation planning in power system control, IEEE Transactions on power systems, Vol. 4, No. 2, pp. 544-550, 1989.

[37]. Mcdonald J. R., Burt G. M., Young D. Y., Alarm processing and fault diagnosis using knowledge based systems for transmission and distribution network control, IEEE Transactions on power systems, Vol. 7, No. 3, pp. 1292-1298, 1992.

[38]. Kaminaris S. D., Machias A. V., Papadias B. C., An intelligent tool for distribution substations troubleshooting and maintenance scheduling, IEEE Transactions on power delivery , Vol. 6, No. 3, pp. 1038-1044, 1991.

[39]. Wollenberg B. F., Sakaguchi T., Artificial intelligence in power system operations, Proceedings of the IEEE, Vol. 75, No. 12, pp. 1678-1685, 1987.

[40]. Smith H. L., Modzelewski T. J., Enhancing energy management systems with advanced RTU capabilities, IEEE computer applications in power, Vol. 2, No. 4, pp. 26-29, 1989.

[41]. Sekine Y., Akimoto Y., Kungui M., Fukui C., Fukui S., Fault diagnosis of power systems, Proceedings of the IEEE, Vol. 80, No. 5, pp. 673-683, 1992.

[42]. Wollenberg B. F., Feasibility study for an energy management system intelligent alarm processor, IEEE Transactions on power systems, Vol. 1, No. 2, pp. 241-246, 1986.

[43]. Amelink H., Forte A. M., Guberman R. P., Dispatcher alarm and message processing, IEEE Transactions on power systems, Vol. 1, No. 3, pp. 188-194, 1986.

[44]. Tesch D. B., Yu D. C., Fu L. M., Vairavan K., A knowledge-based alarm processor for energy management system, IEEE Transactions on power systems, Vol. 5, No. 1, pp. 268-275, 1990.

[45]. Minakawa T., at al., Development and implementation of a power system fault diagnosis expert system, IEEE Transactions on power systems, Vol. 10, No. 2, pp. 932-940, 1995.

[46]. Dahlgren R., at al., Model-based systhesis and suppresion of transformer alarms in a control center environment, IEEE Transactions on power delivery, Vol. 13, No. 3, pp. 843-848, 1998.

[47]. Sidhu T. S., Cruder O., Huff G. J., An abductive inference technique for fault diagnosis in electrical power transmission networks, IEEE Transactions on power delivery, Vol. 12, No. 1, pp. 515-522, 1997.

[48]. Eickhoff F., Handschin E., Hoffman W., Knowledge based alarm handling and fault location in distribution networks, IEEE Power industry computer application conference, pp. 358-364, 1991.

[49]. Vale Z. A., Moura A. M., An expert system with temporal reasoning for alarm processing in power system control centers, IEEE Transactions on power systems, Vol. 8, No. 3, pp. 1307-1341, 1993.

[50]. Wagenbauer M. P., Nejdl W., Integrating model-based and heuristic features in a real-time expert system, IEEE expert, Vol. 8, No. 4, pp. 12-18, 1993.

[51]. Cheng S. J., Malik O. P., Hope G. S., An expert system for voltage and reactive power control of a power system, IEEE Transactions on power systems, Vol. 3, No. 4, pp. 1449-1455, 1988.

[52]. Mcarthur S. D. J., at al., The application of model based reasoning within a decision support system for protection engineers, IEEE Transactions on power delivery, Vol. 11, No. 4, pp. 1748-1754, 1996.

[53]. Hertz A., Fauquembergue P., Fault diagnosis at substation based on sequential event recorders, Proceedings of the IEEE, Vol. 80, No. 5, pp. 684-688, 1992.

[54]. Russell B. D., Watson K., Power substation automation using a knowledge based systems justification and preliminary field experiments, IEEE Transactions on power delivery, Vol. 2, No. 4, pp. 1090-1097, 1987.

[55]. Klein D., Finin T., What's in a deep model, Computer and information science, pp. 595-562, Philadelphia, 1987.

[56]. Sajja P. S., Shah D M., Knowledge based diagnosis of abdomen pain using fuzzy prolog rules, Jurnal of emerging trends in computing and information science, Vol. 1, No. 2, pp. 55-60, 2010.

[57]. Nakatsu R., Diagramatic reasoning in AI, Wily&Sons, ,2010.

[58]. Jorge R. D., Damasio C. V., Diagnosis of power system protection, Springer-Verlag, Berlin, 2006.

[59]. Vale Z. A., Moura A. M., An expert system approach for power system diagnosis,

[60]. Park Y. M., Kim G. W., Sohn J. M., A logic based expert system (LBES) for fault diagnosis of power system, IEEE Transactions on power systems, Vol. 12, No. 1, pp. 363-369, 1997.

[61]. Mcarthur S. D. J., Davidson E. M., Automated post-fault diagnosis of power system disturbances, IEEE Power engineering society general meeting, pp. 1-6, 2006.

[62]. Bau D. Y., Brezillon P. J., Model-based diagnosis of power-station control systems, IEEE Expert, Vol. 7, No. 1, pp. 36-44, 1992.

[63]. Scott W. G., Automating the restoration of distribution services in major emergencies, IEEE Transactions on power delivery, Vol. 5, No. 2, pp. 1034-1039, 1990.

[64]. Bian M., Shi J., Wang S., FTA-based fault diagnose expert system for hydraulic equipments, IEEE Internatinal conference of fluid power and mechatronic, pp. 959-963, 2011.

[65]. Foxvog D., Kurki M., Survey of real-time and on-line diagnostic expert systems, Proceedings Real time systems, pp. 61-69, 1991.

[66]. Kneale J. B., Application of expert system techniques to fault tree diagnostic, data, IEEE Autotestcon proceedings, pp. 100-104, 1997.

[67]. Fink P. K., Lusth J. C., Duran J. W., A general expert system design for diagnostic problem solving, IEEE Transactions on pattern analysis and machine intelligence, Vol. 7, No. 5, pp. 553-560, 1985.

[68]. Warwick K., Ekwue A., Aggarwal R., Artificial intelligence techniques in power systems, IEE The institution of electrical engineers, London, 1997.

[69]. Dillon T. S., Laughton M. A., Expert system applications in power systems, Prentice hall internacional series in power system computation, London, 1990.

[70]. Song Y. H., Johns A., Aggarwal R., Computaional intelligence applications to power systems, Science press & Kluwer academic publisher, London/Beijing, 1996.

[71]. Gers J., Holmes E. J., Protection of electricity distribution networks 2nd edition, IEE the institution of electrical engineers, London, 2004.

[72]. Giarratano J., Riley G., Expert systems principles and programming, PWS publishing company, Boston, 1998.

[73]. Sestito S., Dillon T. S., Automated knowledge acquisition, Prentice hall, Sydney, 1994.

[74]. Luger G. F., Stubblefield W. A., Artificial intelligence and the design of expert systems, The Benjamin/Cummings publishing company, California, 1989.

[75]. Negotia C. V., Expert systems and fuzzy systems, The Bnjamin/Cummings publishing company, California, 1985.

[76]. Durkin J., Expert system design and development, Macmillan publishing company, New York, 1994.

[77]. McDonald J. R., Burt G. M., Zielinski J. S., McArthur S. D. J., Intelligent knowledge based systems in electrical power engineering, Chapman & Hall, London, 1997.

[78]. Merritt D., Building expert systems in Prolog, Springer-Verlag, New York, 1989.

[79]. Waterman D. A., A guide to expert systems, Addison-Wesley publishing company, USA, 1986.

[80]. Goldenthal N., Expert systems and artificial intelligence, Weber systems, Cleveland, 1987.

[81]. Ernst C. J., Management expert systems, Addison-Wesley publishing company, GB, 1988.

[82]. Leonides C. T., Knowledge-based systems techniques and applications, academic press, Vol. 1-4, San Diego, 2000.

[83]. Adibi M. M., Power system restoration, IEEE Press, New York, 2000.

[84]. Song Y. H., Modern optimisation techniques in power systems, Kluwer academic publisher, London, 1999.

[85]. Naser J. A., Expert systems applications for the electric power industry, Hemisphere publishing corporation, Vol. 1-2, New York, 1991.

[86]. Anderson P. M., Power system protection, IEEE Press, New York, 1999.

[87]. DeLong T. W., A fault tree manual, Texas A&M University, 1970.

[88]. Knight U. G., Power systems in emergencies, John Wiley & Sons LTD, Chichester, 2001.

[89]. Mollak V., Fundamentals of risk analysis and risk management, CRC Press, Boca Raton, 1997.

[90]. Sajja P. S., Akerker R., Advanced knowledge-based systems: models, applications and research, TMRF e-Book, Kolhapur, 2010.

[91]. Haimes Y. Y., Risk modeling assesment, and management, John Wiley & Sons, New Jersey, 2009.

[92]. Negnevitsky M., Artificial intelligence, Addison-Wesley, GB, 2002.

[93]. Vachtsevanos G., at al., Intelligent fault diagnosis and prognosis for engineering systems, John Wiley & Sons, New Jersey, 2006.

[94]. Covington M. A., Nute D., Vellino A., Prolog programming in depth, Prentice Hall, New Jersey, 1997.

[95]. McDonald J. D., Electric power substations engineering, CRC Press, Boca Raton, 2007.

[96]. Stobo. J., Problem solving with prolog, Pitman publishing, GB, 1989.

[97]. O'Keefe R. A., The craft of prolog, MIT, 1990.

[98]. Kezunovic M., Liu C. C., McDonald J. R., Smith L., IEEE tutorial on automated fault analysis, Texas A&M University, 2001.

[99]. Ivanov V., Brojboiu M., Ivanov S., Expert system for power transformer diagnosis, Proceedings 26th European conference on modelling and simulation (ECMS), Koblenz, 2012.

[100]. Malandian E., Skarek P., An expert system for accelerator fault diagnosis, 12th IEEE Particle Accelerator Conference, Washington, 1987.

[101]. Kleer J., Williams B. C., Reasoning about multiple faults, AAAI-86, pp. 132-139, 1986.

[102]. Chung D. T., Modarres M., Gotres: An expert system for fault detection and analysis, Elsevier, Vol. 24, No. 2, pp. 113-137, 1989.

[103]. Kim I. S., Modarres M., Application of goal tree-success tree model as the knowledge-base of the operator advisory systems, Nuclear engineering and design, Elsevier, Vol. 104, No. 1, pp. 67-81, 1987.

[104]. Davis R., at al., Diagnosis based on description of structure and function, AAAI-82, pp. 137-142, 1982.

[105]. Hamscher W., Using structural and functional information in diagnostic design, AAAI-83, pp. 152-156, 1983.

[106]. Genesereth M. R., Diagnosis using hierarchical design models, AAAI-82, pp. 278-283, 1982.

[107]. Srihari S. N. Chen J. S., Candidate ordering and elimination in model-based fault diagnosis, Proceedings of the eleventh international joint conference on artificial intelligence, pp. 1363-1368, 1989.

[108]. Laffey T. J., Perkins W. A., Nguyen T. A., Reasoning about fault diagnosis with les, IEEE Expert, Vol. 1, No. 1, pp. 13-20, 1986.

[109]. Družovec M., Šostar A., Welzer T., Model based diagnoses in medicine, 1998 IEEE International conference on systems, man, and cybernetics, Vol. 4, pp. 4080-4085, 1998.

[110]. Milne R., Fault diagnosis through responsibility, IJCAI' 85 Proceedings of the 9th international joint conference on artificial intelligence, Vol. 1, pp. 423-425, 1985.

[111]. Kim I. S., Modarres M., Hunt R. N. M., A model-based approach to on-line process disturbance management: The models, Tehnical research report, TR 88-111, 1988.

[112]. Lapp S. A., Powers G. J., Computer-aided synthesis of fault-trees, IEEE Transaction on reliability, Vol. R-26, No. 1, pp. 2-13, 1977.

[113]. Henley E. J., Kumamoto H., Comment on: Computer-aided synthesis of fault-trees, IEEE Transaction on reliability, Vol. R-26, No. 5, pp. 316-317, 1977.

[114]. Lambert H. E., Comments on the Lapp-Powers "Computer-aided synthesis of fault-trees", IEEE Transaction on reliability, Vol. R-28, No. 1, pp. 2-13, 1979.

[115]. Yellman T. W., Comment on: "Comment on computer-aided synthesis of fault-trees", IEEE Transaction on reliability, Vol. R-28, No. 1, pp. 10-11, 1979.

[116]. Leinweber D., Expert systems in space, IEEE Expert, Vol. 2, No. 1, pp. 26-36, 1987.

[117]. Bernard J. P., Durocher D., An expert system for fault diagnosis integrated in existing SCADA systems, IEEE Power industry computer application conference, pp. 313-319, 1993.

[118]. Beschata A., at. al., A model-based approach to fault localisation in power transmission networks, IEEE Intelligent system engineering, Vol. 2, No. 1, pp. 3-14, 1993.

[119]. Bell S. C., at al., Model-based analysis of protection system performance, IEE Proceedings- Generation, Transmission and Distribution, Vol. 145, No. 5, pp.547-552, 1998.

[120]. Nelson W. R., An expert system for diagnosis and treatment of nuclear reactor accidents, AAAI-82, pp. 296-301, 1982.

[121]. Yoon W. C., Hammer J. M., Deep-reasoning fault diagnosis: An aid and a model, IEEE Transaction on systems man and cybernetics, Vol. 18, No. 4, pp. 659-676, 1988.

[122]. Davis R., Diagnostic reasoning based on structure and behavior, MIT Artificial intelligence laboratory, 1984.

[123]. Kuipers B., Artificial Intelligence: Commonsense reasoning about casuality: Deriving behavior from structure, Elseviere, Vol. 24, pp. 169-203, 1984.

[124]. Rieger C., Grinberg M., The declarative representation and procedural simulation of causality in phisical mechanisms, Proceedings of the 5th international joint conference on artificial intelligence, Vol. 1, pp 250-256, 1977.

[125]. Barrow H. G., Proving the correctness of digital hardwear designs, National conference on artificial intelligence AAAI-83, pp.17-21, 1983.

[126]. Console L., Dreessier O., Model-based diagnosis in the real world: lessons learned and challenges remaining, IJCAI' 99 Proceedings of the 16th international joint conference on artificial inteligence, Vol. 2, pp. 1393-1400, 1999.

[127]. Forbus K. D., Artificial Intelligence: Qualitative process theory, Elseviere, Vol. 24, pp. 85-168, 1984.

[128]. Reiter R., Artificial Intelligence: A theory of diagnosis from first principle, Elseviere, Vol. 32, pp. 57-95, 1987.

[129]. Hamscher W., Using structural and functional information in diagnostic design, MIT Artificial intelligence laboratory, 1983.

[130]. Picardi C., A short tutorial on model-based diagnosis.

[131]. Bredeweg B., Struss P., Current topics in qualitative reasoning, AAAI, pp. 13-16, 2003.

[132]. Williams B. C., Kleer J., Qualitative reasoning about physical systems: a return to roots, Elseviere, Vol. 51, pp. 1-9, 1991.

[133]. Huang Y. C., Yang H. T., Huang C. L., A new intelligent hierarchical fault diagnosis system, IEEE Transactions on power systems, Vol. 12, No. 1, 1997.

[134]. Prince W. R., Wollenberg B. F., Bertagnolli D. B., Survey on excessive alarms, , IEEE Transactions on power systems, Vol. 4, No. 3, 1989.

[135]. Sakaguchi T., Matsumoto K., Development of a knowledge based system for power system restoration, IEEE Transactions on power apparatus and systems, Vol. 102, No. 2, 1983.

[136]. Bratko I., Mozetič I., Lavrač N., KARDIO: A study in deep and qualitative knowledge for expert systems, MIT press, London, 1989.

[137]. David J. M., Krivine J. P., Simmons R., Second generation expert systems, Springer-Verlag, Berlin, 1993.

[138]. D'Ambrosio B., Qualitative process theory using linguistic variables, Springer-Verlag, New York, 1989.

[139]. Walters J. R., Nielsen N. R., Crafting knowledge-based systems, Wiely&Sons, New York, 1988.

[140]. Bennet A. W., Introduction to computer simulation, West publishing company, St. Paul, 1974.

[141]. Reggia A. J., at. al., Diagnostic expert systems based on a set covering model, Int. J. Man-machine studies, Vol. 19, pp. 437-460, 1983.

[142]. Venkatasubramanian V., at. al., A review of process fault detection and diagnosis, Part 2: Qualitative models and search strategies, Elsevier, Vol. 27, pp. 313-326, 2003.

[143]. Fault tree handbook , U.S. Nuclear Regulatory Commision, 1981.

[144]. Fault tree handbook with aerospace applications, NASA Headquarters, 2002.

[145]. Curriculum for learning about QR modeling, University of Amsterdam, 2006.

[146]. Monsef H., Ranjbar A. M., Jadid S., Fuzzy rule-based expert system for power system fault diagnosis, IEE Proceedings- Generation, Transmission and Distribution, Vol. 144, No. 2, pp.186-192, 1997.

[147]. Chang C. S., at. al., Fuzzy logic approach in power system fault section identification, IEE Proceedings- Generation, Transmission and Distribution, Vol. 144, No. 5, pp.406-414, 1997.

[148]. Jarventausta P., at. al., Using fuzzy sets to model the uncertainity in the fault location process of distribution networks, IEEE Transactions on power delivery, Vol. 9, No. 2, 1994.

[149]. Lee J. H., at.al., A fuzzy expert system for the integrated fault diagnosis, IEEE Transactions on power systems, Vol. 15, No. 2, 2000.

[150]. Meza E. M., at. al., Exploring fuzzy relations for alarm processing and fault location in electric power systems, IEEE Porto Power tech conference, 2001.

[151]. Tomsovic K., Chow M. Y., Tutorial on fuzzy logic applications in power system, IEEE-PES Winter meeting in Singapore, 2000.

[152]. Chen W. H. at. al., On-line fault diagnosis of distribution substations using hybrid cause-effect network and fuzzy rule-based method, IEEE Transactions on power delivery, Vol. 15, No. 2, pp. 410-417, 2000.

[153]. Cho H. J., Park J. K., An expert system for fault section diagnosis of power system using fuzzy relations, IEEE Transactions on power systems, Vol. 12, No. 1, pp. 342-348, 2000.

[154]. Tan J. C., Crossley P. A., McLaren P. G., Fuzzy expert system for on-line fault diagnosis on a transmission network, IEEE, 2001.

[155]. Min S. W., at. al., A fuzzy relation based fault section diagnosis method for power systems using operating sequences of protective devices, IEEE, 2001.

[156]. Klir G. J., Yuan B., Fuzzy sets and fuzzy logic, Prentice Hall, New Jersey, 1995.

[157]. Terano T., Asai K., Sugeno M., Applied fuzzy systems, Ap profesional, USA, 1994.

[158]. Akerkar R. A., Sajja P. S., Knowledge-based systems, Jones and Barlett, USA, 2010.

[159]. Gottwald S., Fuzzy sets and fuzzy logic, Vieweg, Germany, 1993.

[160]. Momoh J. A., Sobajic D., Dolce J., An evaluation of intelligent systems for fault diagnosis., IEEE Internacional conference, Vol. 1, pp. 413-418, 1994.

[161]. Angeli C., Chatzinikolaou A., On-line fault detection techniques for technical systems: A Survey, IJCS, Vol. 1, No. 1, pp. 12-30, 2004.

[162]. Saha M. M., Izykowski J., Rosolowski E., Fault location on Power Networks, Springer-Verlag, London, 2010.

[163]. Saxena D., at. al., Application of computional intelligence in emerging power systems, IJEST, Vol. 2, No. 3, pp. 1-7, 2010.

[164]. Chi K., Abramson B., Uncertainty management in expert systems, IEEE, pp. 29-48, 1990.

[165]. Carmona C. J., at. al., An analysis on the use of pre-processing methods in evolutionary fuzzy systems for subgroup discovery, Elseviere, Vol. 39, No. 11, pp. 404-412, 2012.

[166]. Allison P. D., Missing data, Sage publications, USA, 2002.

[167]. Little R. J. A., Rubin D. B., Statistical analysis with missing data, John Wiley ¸& Sons, California, 1987.

[168]. Davey A., Savla J., Statistical power analysis with Missing data, Routledge, USA, 2010.

[169]. Nacional research council., The prevention and treatment of missing data in clinical trials, The nacional Academies press, Washington, 2010.

[170]. Weisberg H. F., Total survey Error approach: A guide to the new science of survey reasearch, The university of Chichago press, USA, 2005.

[171]. Snijkers G., at. al, Designing and condacting businness surveys, Wiley, USA, 2013.

[172]. Wall De T., Pannekoke J., Scholtus S., Handbook of statistical data editing and imputaion, Wiley, USA/Canada, 2011.

[173]. Cox B G., at. al., Business survey methods, Wiley, New York, 1995.

[174]. Peng L., Lei L., A review of missing dana treatmant methods, Department on information systems, Shanghai University, 2004.

[175]. Benedetti R., Bee M., Espa G., Piersimoni F., Agricultural survey methods, Wiley, UK, 2010.

[176]. Grahm J. W., Missing dana alalysis and design, Springer, USA, 2012.

[177]. Enders C. K., Applied missing dana analysis, The Guilford press, New York, 2010.

[178]. Pospiech-Kurakowska S., Processing of missing dana in fuzzy system, Springer, pp. 453-460, 2008.

[179]. Berthold M. R., Huber K. P., Missing values and learning of fuzzy rules, IJOU, 1998.

[180]. Wilmots B., Shen Y., Hermans E., Ruan D., Missing dana treatment, Universitet Hasselt, 2011.

[181]. Marwala T., Computational intelligence for missing dana imputation, estimation, and management: Knowledge optimization techniques; Information science reference, New York , 2009.

[182]. Daniels M. J., Hogan J. W., Missing dana in longitudinal studies, Chapman & Hall/CRC, USA, 2008.

[183]. Ross J. T., Fuzzy logic with engineering appliacations, Wiley, USA, 2010.

[184]. Klement E. P., Meisar R., Pap E., Triangular norms, Springer, Germany, 2000.

[185]. Kecman V., Learning and soft computing., The MIT Press, London, 2001.

[186]. Zimmermann H. J., Fuzzy set theory, Kluwer Academic Publishers, London, 1996.

[187]. Straczewski J. T., Advanced concepts in fuzzy logic and systems with membership uncertainty, Springer, New York, 2013.

[188]. Kaluđer S., Miletić S., Nikolovski S., Alarm analysis in electric pover system based on expert system, Technical Gazzete, Slavonski Brod, Vol. 19, No. 4, pp. 709-715, 2012.

[189]. Kaluđer S., Nikolovski S., Majdandžić Lj., Alarm processing in a power system by human expert, Technical Gazzete, Slavonski Brod, Vol. 20, No. 2, pp. 343-349, 2013.

[190]. British Standard (BS 142), 1966.

[191]. IEC 60255, 1988.

[192]. Indian Standarad (IS 3231), 1987.

[193]. Distribution automation handbook, ABB, 2011.

[194]. Network protection & automation guide, ALSTOM, 2011.

DODATAK

Dodatak A:

```
%%%%%%%%%%%%%%%%%%%%%% FUZZY EXPERT SYSTEM WRITEN IN PROLOG   %%%.


%%%%% godina: 2014.
%%%%% program: SWI Prolog.
%%%%% svrha: Dijagnoza kvara u distributivnoj mreži.
%%%%% autor: Slaven Kaluđer, dipl.ing.




%%%%%%%%%%           VP10kV.
%%%%%%%%%%%%%.
%%%%%%%%%%%%%.


%%%%%%%%% ispravno djelovanje nadstrujne zaštite na VP 10 kV.

ro_oc10kv(A1,T1,A2,T2,L,1):-alarm1(A1),alarm2(A2),lokacija(L),(T2-
T1)>=1,(T2-T1)<1.04.
ro_oc10kv(A1,T1,A2,T2,L,M):-alarm1(A1),alarm2(A2),lokacija(L),(T2-
T1)>=1.04, (T2-T1)<1.1, M is 18.34-16.67*(T2-T1).

%%%%%%% krivo djelovanje nadstrujne zaštite na VP 10 kV.

rfo_oc10kv(A1,T1,A2,T2,L,M):-alarm1(A1),alarm2(A2),lokacija(L),(T2-
T1)>=0,(T2-T1)<0.5, M is 2*(T2-T1).
rfo_oc10kv(A1,T1,A2,T2,L,1):-alarm1(A1),alarm2(A2),lokacija(L),(T2-
T1)>0.5,(T2-T1)<0.54.
rfo_oc10kv(A1,T1,A2,T2,L,M):-alarm1(A1),alarm2(A2),lokacija(L),(T2-
T1)>0.54,(T2-T1)<1, M is 2.17-2.17*(T2-T1).
rfo_oc10kv(A1,T1,A2,T2,L,M):-alarm1(A1),alarm2(A2),lokacija(L),(T2-
T1)>=1,(T2-T1)<1.5, M is 2*(T2-T1)-2.
rfo_oc10kv(A1,T1,A2,T2,L,1):-alarm1(A1),alarm2(A2),lokacija(L),(T2-
T1)>=1.5,(T2-T1)<1.54.
rfo_oc10kv(A1,T1,A2,T2,L,M):-alarm1(A1),alarm2(A2),lokacija(L),(T2-
T1)>=1.54,(T2-T1)=<2, M is 4.34-2.17*(T2-T1).


%%%%% otkazivanje djelovanja nadstrujne zaštite na VP 10kV.

rfto_oc10kv(A1,T1,N,L,M):-alarm1(A1),ninf(N),lokacija(L), M is 0.67.
alarm1(rstart_oc).
alarm2(rtrip_oc).
ninf(nortrip_oc).

%%%%%% ispravno djelovanje kratkospojnog releja na VP 10kV.

ro_sc10kv(A3,T1,A4,T2,L,1):-alarm3(A3),alarm4(A4),lokacija(L),(T2-
T1)>=0,(T2-T1)<0.04.
```

```
ro_sc10kv(A3,T1,A4,T2,L,M):-alarm3(A3),alarm4(A4),lokacija(L),(T2-
T1)>=0.04,(T2-T1)<0.1, M is 1.67-16.64*(T2-T1).

%%%%%% krivo djelovanje kratkospojnog releja na VP 10kV.

rfo_sc10kv(A3,T1,A4,T2,L,M):-alarm3(A3),alarm4(A4),lokacija(L),(T2-
T1)>=0,(T2-T1)<0.5, M is 2*(T2-T1).
rfo_sc10kv(A3,T1,A4,T2,L,1):-alarm3(A3),alarm4(A4),lokacija(L),(T2-
T1)>0.5,(T2-T1)<0.54.
rfo_sc10kv(A3,T1,A4,T2,L,M):-alarm3(A3),alarm4(A4),lokacija(L),(T2-
T1)>0.54,(T2-T1)<1, M is 2.17-2.17*(T2-T1).

%%%%%% otkazivanje djelovanja kratkospojnog releja na VP 10 kV.

rfto_sc10kv(A3,T1,N,L,M):-alarm3(A3),ninf1(N),lokacija(L),    M    is
0.67.

alarm3(rstart_sc).
alarm4(rtrip_sc).
ninf1(nortrip_sc).

%%%%%%  ispravno djelovanje zemljospojnog releja koji štiti VP 10
kV.

ro_ef10kv(A5,T1,A6,T2,L,1):-alarm5(A5),alarm6(A6),lokacija(L),(T2-
T1)>=0,(T2-T1)<0.04.
ro_ef10kv(A5,T1,A6,T2,L,M):-alarm5(A5),alarm6(A6),lokacija(L),(T2-
T1)>=0.04,(T2-T1)<0.1, M is 1.67-16.64*(T2-T1).

%%%%%   krivo djelovanje zemljospojnog releja koji štiti VP 10 kV.

rfo_ef10kv(A5,T1,A6,T2,L,M):-alarm5(A5),alarm6(A6),lokacija(L),(T2-
T1)>=0,(T2-T1)<0.5, M is 2*(T2-T1).
rfo_ef10kv(A5,T1,A6,T2,L,1):-alarm5(A5),alarm6(A6),lokacija(L),(T2-
T1)>0.5,(T2-T1)<0.54.
rfo_ef10kv(A5,T1,A6,T2,L,M):-alarm5(A5),alarm6(A6),lokacija(L),(T2-
T1)>0.54,(T2-T1)<1, M is 2.17-2.17*(T2-T1).

%%%%%%     otkazivanje djelovanja zemljospojnog releja koji štiti
VP 10kV.

rfto_ef10kv(A5,T1,N,L,M):-alarm5(A5),ninf2(N),lokacija(L),    M    is
0.67.

alarm5(rstart_ef).
alarm6(rtrip_ef).
ninf2(nortrip_ef).



%%%%%%%%%  TRANSFORMATOR.
%%%%%%%%%%.
%%%%%%%%%%.
```

```
%%%%%%% ispravno djelovanje nadstrujnog releja koji štiti
transformator.

ro_octr(A7,T1,A8,T2,L,1):-alarm7(A7),alarm8(A8),lokacija1(L),(T2-
T1)>=1.5,(T2-T1)<1.54.
ro_octr(A7,T1,A8,T2,L,M):-alarm7(A7),alarm8(A8),lokacija1(L),(T2-
T1)>=1.54, (T2-T1)<1.6, M is 26-16.67*(T2-T1).


%%%%%% krivo djelovanje nadstrujnog releja koji štiti transformator.

rfo_octr(A7,T1,A8,T2,L,M):-alarm7(A7),alarm8(A8),lokacija1(L),(T2-
T1)>=0,(T2-T1)<1, M is (T2-T1).
rfo_octr(A7,T1,A8,T2,L,1):-alarm7(A7),alarm8(A8),lokacija1(L),(T2-
T1)>=1,(T2-T1)<1.04.
rfo_octr(A7,T1,A8,T2,L,M):-alarm7(A7),alarm8(A8),lokacija1(L),(T2-
T1)>=1.04,(T2-T1)<1.5, M is 3.26-2.17*(T2-T1).
rfo_octr(A7,T1,A8,T2,L,M):-alarm7(A7),alarm8(A8),lokacija1(L),(T2-
T1)>=1.5,(T2-T1)<2, M is 2*(T2-T1)-3.
rfo_octr(A7,T1,A8,T2,L,1):-alarm7(A7),alarm8(A8),lokacija1(L),(T2-
T1)>=2,(T2-T1)<2.04.
rfo_octr(A7,T1,A8,T2,L,M):-alarm7(A7),alarm8(A8),lokacija1(L),(T2-
T1)>=2.04,(T2-T1)=<3, M is 3.12-1.04*(T2-T1).


%%%%% otkazivanje djelovanja nadstrujnog releja koji štiti trafo.

rfto_octr(A7,T1,N,L,M):-alarm7(A7),ninf3(N),lokacija1(L), M is 0.67.

alarm7(rstart_oc).
alarm8(rtrip_oc).
ninf3(nortrip_oc).


%%%%%%        DALEKOVOD 35 kV.
%%%%%%%%%%.
%%%%%%%%%%.

%%%%%%%%% ispravno djelovanje nadstrujne zaštiti na VP 35 kV.

ro_oc35kv(A9,T1,A10,T2,L,1):-
alarm9(A9),alarm10(A10),lokacija2(L),(T2-T1)>=2.3,(T2-T1)<2.34.
ro_oc35kv(A9,T1,A10,T2,L,M):-
alarm9(A9),alarm10(A10),lokacija2(L),(T2-T1)>=2.34,   (T2-T1)<2.6,   M
is 10-3.85*(T2-T1).

%%%%%%% krivo djelovanje nadstrujne zaštiti na VP 35 kV.

rfo_oc35kv(A9,T1,A10,T2,L,M):-
alarm9(A9),alarm10(A10),lokacija2(L),(T2-T1)>=0,(T2-T1)<1.5,   M   is
0.67*(T2-T1).
rfo_oc35kv(A9,T1,A10,T2,L,1):-
alarm9(A9),alarm10(A10),lokacija2(L),(T2-T1)>1.5,(T2-T1)<1.54.
rfo_oc35kv(A9,T1,A10,T2,L,M):-
alarm9(A9),alarm10(A10),lokacija2(L),(T2-T1)>1.54,(T2-T1)<2.3,  M  is
3.03-1.32*(T2-T1).
```

```
rfo_oc35kv(A9,T1,A10,T2,L,M):-
alarm9(A9),alarm10(A10),lokacija2(L),(T2-T1)>=2.3,(T2-T1)<3.1,  M  is
1.25*(T2-T1)-2.875.
rfo_oc35kv(A9,T1,A10,T2,L,M):-
alarm9(A9),alarm10(A10),lokacija2(L),(T2-T1)>=3.1,(T2-T1)<3.14.
rfo_oc35kv(A9,T1,A10,T2,L,M):-
alarm9(A9),alarm10(A10),lokacija2(L),(T2-T1)>=3.14,(T2-T1)=<4.6,    M
is 3.15-0.68*(T2-T1).

%%%%% otkazivanje djelovanja nadstrujne zaštite na VP 35kV.

rfto_oc35kv(A9,T1,N,L,M):-alarm9(A9),ninf4(N),lokacija2(L),   M   is
0.67.

alarm9(rstart_oc).
alarm10(rtrip_oc).
ninf4(nortrip_oc).

%%%%%% ispravno djelovanje kratkospojnog releja na VP 35kV.

ro_sc35kv(A11,T1,A12,T2,L,1):-
alarm11(A11),alarm12(A12),lokacija2(L),(T2-T1)>=0.3,(T2-T1)<0.34.
ro_sc35kv(A11,T1,A12,T2,L,M):-
alarm11(A11),alarm12(A12),lokacija2(L),(T2-T1)>=0.34,(T2-T1)<0.4,   M
is 6.67-16.64*(T2-T1).

%%%%%%% krivo djelovanje kratkospojne zaštite na VP 10 kV.

rfo_sc35kv(A11,T1,A12,T2,L,M):-
alarm11(A11),alarm12(A12),lokacija2(L),(T2-T1)>=0,(T2-T1)<0.2,  M  is
5*(T2-T1).
rfo_sc35kv(A11,T1,A12,T2,L,1):-
alarm11(A11),alarm12(A12),lokacija2(L),(T2-T1)>=0.2,(T2-T1)<0.24.
rfo_sc35kv(A11,T1,A12,T2,L,M):-
alarm11(A11),alarm12(A12),lokacija2(L),(T2-T1)>=0.24,(T2-T1)<0.3,   M
is 5-16.67*(T2-T1).
rfo_sc35kv(A11,T1,A12,T2,L,M):-
alarm11(A11),alarm12(A12),lokacija2(L),(T2-T1)>=0.3,(T2-T1)<0.4,    M
is 10*(T2-T1)-3.
rfo_sc35kv(A11,T1,A12,T2,L,1):-
alarm11(A11),alarm12(A12),lokacija2(L),(T2-T1)>=0.4,(T2-T1)<0.44.
rfo_sc35kv(A11,T1,A12,T2,L,M):-
alarm11(A11),alarm12(A12),lokacija2(L),(T2-T1)>=0.44,(T2-T1)=<0.6,  M
is 3.75-6.25*(T2-T1).

%%%%% otkazivanje djelovanja kratkospojne zaštite na VP 35kV.

rfto_sc35kv(A11,T1,N,L,M):-alarm11(A11),ninf5(N),lokacija2(L),  M  is
0.67.

alarm11(rstart_sc).
alarm12(rtrip_sc).
ninf5(nortrip_sc).

%%%%%% ispravno djelovanje zemljospojnog releja koji štiti VP 35 kV.
```

```
ro_ef35kv(A13,T1,A14,T2,L,1):-
alarm13(A13),alarm14(A14),lokacija2(L),(T2-T1)>=1.2,(T2-T1)<1.24.
ro_ef35kv(A13,T1,A14,T2,L,M):-
alarm13(A13),alarm14(A14),lokacija2(L),(T2-T1)>=1.24,(T2-T1)<1.3,   M
is 21.67-16.67*(T2-T1).


%%%%%%   krivo djelovanje nadstrujnog releja koji štiti VP 35 kV.

rfo_ef35kv(A13,T1,A14,T2,L,M):-
alarm13(A13),alarm14(A14),lokacija2(L),(T2-T1)>=0,(T2-T1)<1,   M   is
(T2-T1).
rfo_ef35kv(A13,T1,A14,T2,L,1):-
alarm13(A13),alarm14(A14),lokacija2(L),(T2-T1)>1,(T2-T1)<1.04.
rfo_ef35kv(A13,T1,A14,T2,L,M):-
alarm13(A13),alarm14(A14),lokacija2(L),(T2-T1)>1.04,(T2-T1)<1.2,    M
is 7.5-6.25*(T2-T1).
rfo_ef35kv(A13,T1,A14,T2,L,M):-
alarm13(A13),alarm14(A14),lokacija2(L),(T2-T1)>=1.2,(T2-T1)<1.4,    M
is 5*(T2-T1)-6.
rfo_ef35kv(A13,T1,A14,T2,L,1):-
alarm13(A13),alarm14(A14),lokacija2(L),(T2-T1)>=1.4,(T2-T1)<1.44.
rfo_ef35kv(A13,T1,A14,T2,L,M):-
alarm13(A13),alarm14(A14),lokacija2(L),(T2-T1)>=1.44,(T2-T1)=<2.4,  M
is 1.04*(T2-T1)+2.5.


%%%%%%     otkazivanje zemljospojnog releja koji štiti VP 35 kV.

rfto_ef35kv(A13,T1,N,L,M):-alarm13(A13),ninf6(N),lokacija2(L),  M  is
0.67.

alarm13(rstart_ef).
alarm14(rtrip_ef).
ninf6(nortrip_ef).


%%%%%%  PREKIDAČI.
%%%%%%%%%%%%%%%%%%.
%%%%%%%%%%%%%%%%%%.


%%%%%%%  VP 10 kV.


%%%%%%   ispravno djelovanje prekidača na VP 10 kV.

cbo_10kv(A2,T1,A15,T2,L,M):-alarm2(A2),alarm15(A15),lokacija(L),(T2-
T1)+1>0.94,(T2-T1)+1<1.04, M is 10*((T2-T1)+1)-9.4.
cbo_10kv(A2,T1,A15,T2,L,M):-alarm2(A2),alarm15(A15),lokacija(L),(T2-
T1)+1>=1.04,(T2-T1)+1<1.1, M is 18.34-16.67*((T2-T1)+1).
cbo_10kv(A4,T1,A15,T2,L,M):-alarm4(A4),alarm15(A15),lokacija(L),(T2-
T1)>0.04,(T2-T1)<0.1, M is 1.67-16.64*(T2-T1).

%%%%%%      krivo djelovanje prekidača na VP 10 kV provjeri ovih
0.6179.
```

```
cbfo_10kV(N,A15,T2,L,M):-ninf(N),alarm15(A15),lokacija(L),M       is
0.6179.

%%%%%%    otkazivanje djelovanja prekidača na VP 10 kV.

cbfto_10kv(A2,T1,N,L,M):-alarm2(A2),ninf7(N),lokacija(L),    M    is
0.218.

alarm2(rtrip_oc).
alarm15(cbopen10kv).
ninf(nortrip_oc).
ninf7(cbclose_10kv).

%%%%%%   TRANSFORMATOR.


%%%%%%   ispravno djelovanje oba prekidača na trensformatoru.

cbso_tr(A8,T1,A16,T2,L,M):-alarm8(A8),alarm16(A16),lokacija1(L),(T2-
T1)+1.5>=1.44,(T2-T1)+1.5<1.54, M is 10*((T2-T1)+1.5)-14.4.
cbso_tr(A8,T1,A16,T2,L,M):-alarm8(A8),alarm16(A16),lokacija1(L),(T2-
T1)+1.5>=1.54,(T2-T1)+1.5<1.6, M is 26.67-16.67*((T2-T1)+1.5).

%%%%%   krivo djelovanje oba prekidača na transformatoru.

cbsfo_tr(N,A16,T1,L,M):-ninf3(N),alarm16(A16),lokacija1(L),   M   is
0.704.


%%%%%  otkazivanje oba prekidača na transformatoru.
%

cbsfto_tr(A8,T1,N,L,M):-alarm8(A8),ninf8(N),lokacija1(L),    M    is
0.316.


alarm8(rtrip_oc).
alarm16(cbs_open_tr).
ninf3(nortrip_oc).
ninf8(cbsclose_tr).


%%%%%%%  DALEKOVOD 35 kV.


%%%%%%  ispravno djelovanje prekidača na dalekovodu 35 kV.

cbo_35kv(A10,T1,A17,T2,L,M):-
alarm10(A10),alarm17(A17),lokacija2(L),(T2-T1)+2.3>2.04,(T2-
T1)+2.3<2.34, M is 3.34*((T2-T1)+2.3)-6.8.
cbo_35kv(A10,T1,A17,T2,L,M):-
alarm10(A10),alarm17(A17),lokacija2(L),(T2-T1)+2.3>=2.34,(T2-
T1)+2.3<2.6, M is 10-3.85*((T2-T1)+2.3).
```

```
cbo_35kv(A12,T1,A17,T2,L,M):-
alarm12(A12),alarm17(A17),lokacija2(L),(T2-T1)+0.3>0.35,(T2-
T1)+0.3<0.4, M is 6.67-16.64*((T2-T1)+0.3).

alarm10(rtrip_oc).

%%%%%%   krivo djelovanje prekidača na dalekovodu 35 kV.

cbfo_35kv(N,A17,T1,L,M):-ninf4(N),alarm17(A17),lokacija2(L),   M   is
0.746.

ninf4(nortrip_oc).

%%%%%%  otkazivanje djelovanja prekidača na dalekovodu 35 kV.

cbfto_35kv(A10,T1,N,L,M):-alarm10(A10),ninf9(N),lokacija2(L),   M   is
0.494.


alarm17(cbopen35kv).
ninf9(cbclose_35kv).


%%%%%%%%%%%%   JEDNOSTUKI KVAROVI %%%%%%%%%%%%%%%%.
%%%%%%%%%%%%.
%%%%%%%%%%%%.


sekcija10(R,A,P,B,L,M):-ro10(R),cbo10(P),lokacija(L), M is (2*A+2*B-
3*A*B-A^2-A*B^2+A^2*B^2)/(2-2*A*B).
ro10(ro_oc10kV).
ro10(rfo_oc10kV).
cbo10(cbo10kV).
lokacija(vp_10kV).


sekcijatr(R,A,P,B,L,M):-rotr(R),cbsotr(P),lokacija1(L),      M      is
(2*A+2*B-3*A*B-A^2-A*B^2+A^2*B^2)/(2-2*A*B).
rotr(ro_octr).
cbsotr(cbso_tr).
lokacija1(tr_polje1).
lokacija1(tr_polje2).


sekcija35(R,A,P,B,L,M):-ro35(R),cbo35(P),lokacija2(L),      M      is
(2*A+2*B-3*A*B-A^2-A*B^2+A^2*B^2)/(2-2*A*B).
ro35(ro_oc35kV).
cbo35(cbo35kV).
lokacija2(vp_35kV).

%%%%%%%   VIŠESTRUKI KVAROVI  %%%%%%%%%%%%%%%%%%%%%.
%%%%%%%%.
%%%%%%%%.

sekcija10_tr(F10,A,FTR,B,M,L):-lok10(F10),loktr(FTR),      M      is
min(A,B),lok10tr(L).
```

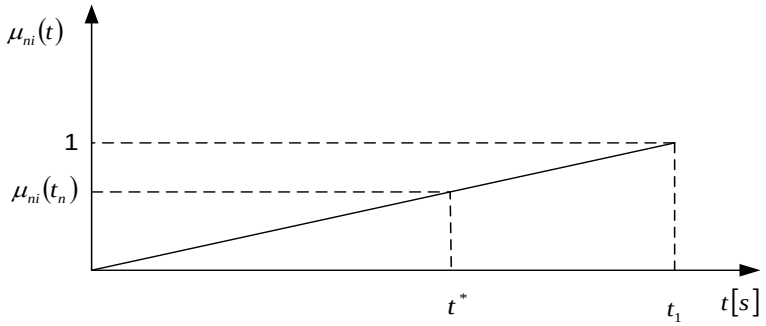
```
lok10(vp10kv).
loktr(transformator).
lok10tr(simultani_kvar_VP10kV_i_transformator).

sekcija10_35(F10,A,F35,B,M,L):-lok10(F10),lok35(F35),      M      is
min(A,B),lok1035(L).
lok35(vp35kv).
lok1035(simultani_kvar_VP10kV_i_VP35kV).

sekcija35_tr(F35,A,FTR,B,M,L):-lok35(F35),loktr(FTR),      M      is
min(A,B),lok35tr(L).
lok35tr(simultani_kvar_VP35kV_i_transformator).
```

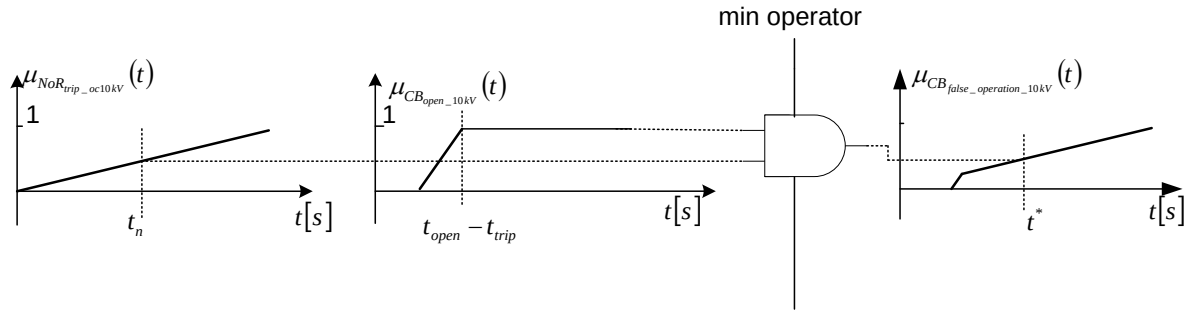
Dodatak B-Defuzifikacija

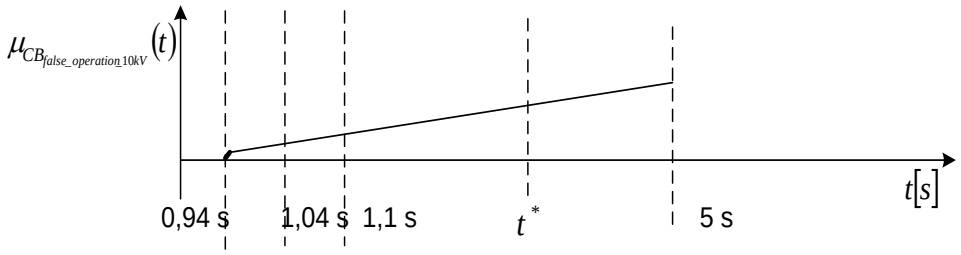
a) Otkazivanje djelovanja svih releja



$$t^* = \frac{\int_0^5 0.2t^2 dt}{\int_0^5 0.2t dt} = 3.34 \rightarrow \mu(t^*) = 0.67$$

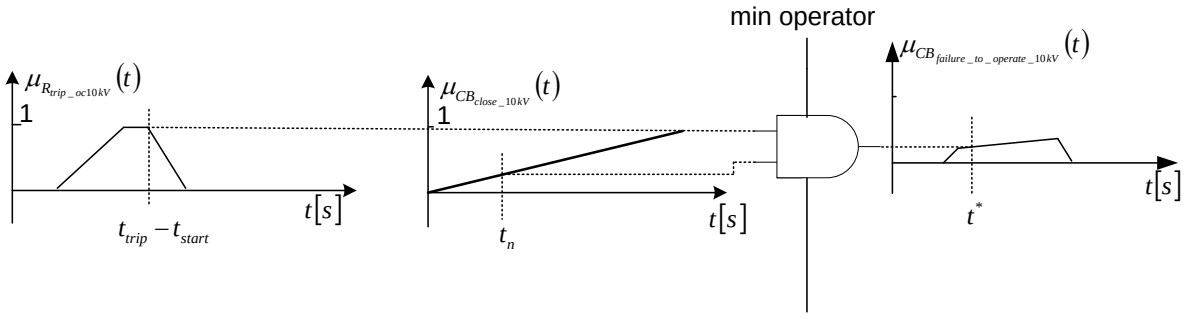
b) Krivo djelovanje prekidača na dalekovodu 10 kV

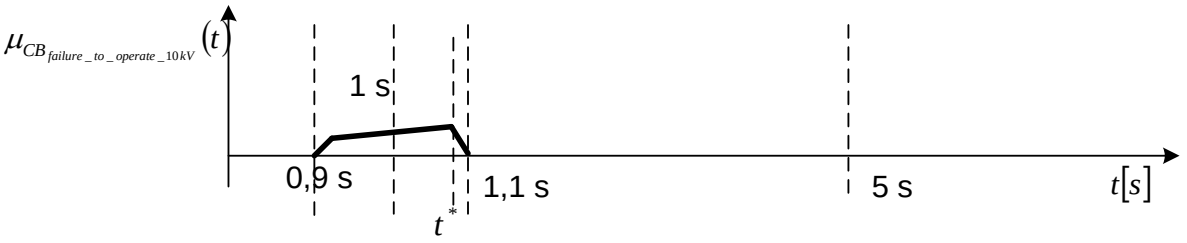




$$t^* = \frac{\int_{0.94}^{0.96} (10t - 9.4)tdt + \int_{0.96}^{5} 0.2t^2 dt}{\int_{0.94}^{0.96} (10t - 9.4)tdt + \int_{0.96}^{5} 0.2tdt} = 3.41 \rightarrow \mu(t^*) = 0.682$$

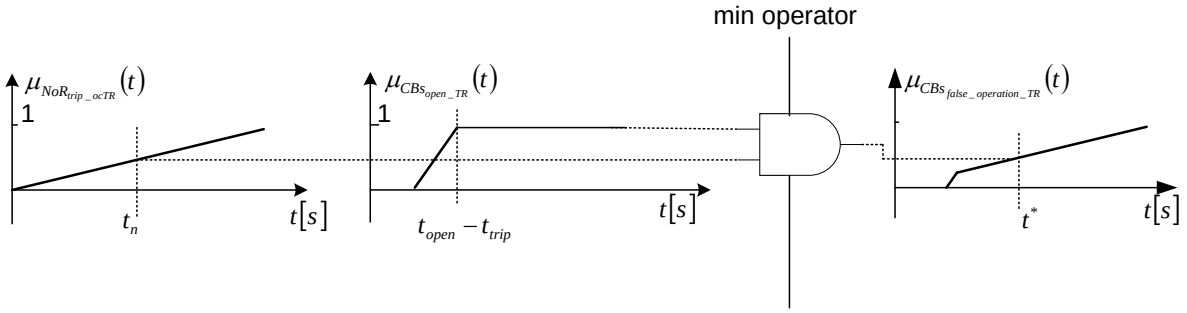
b) Otkazivanje djelovanja prekidača na dalekovodu 10 kV

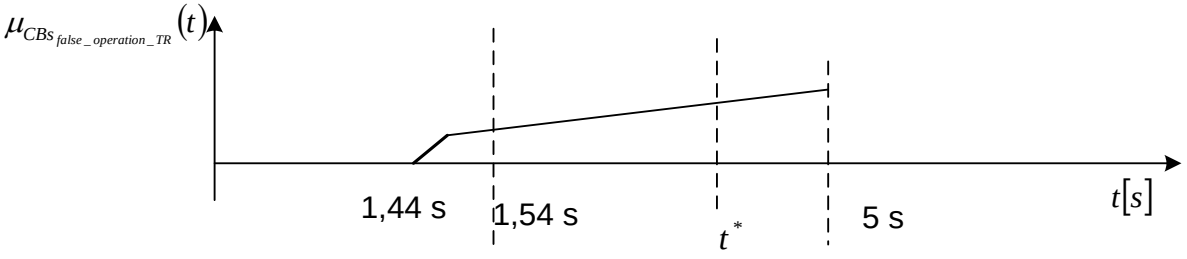




$$\mu(1.09) = 0.218$$

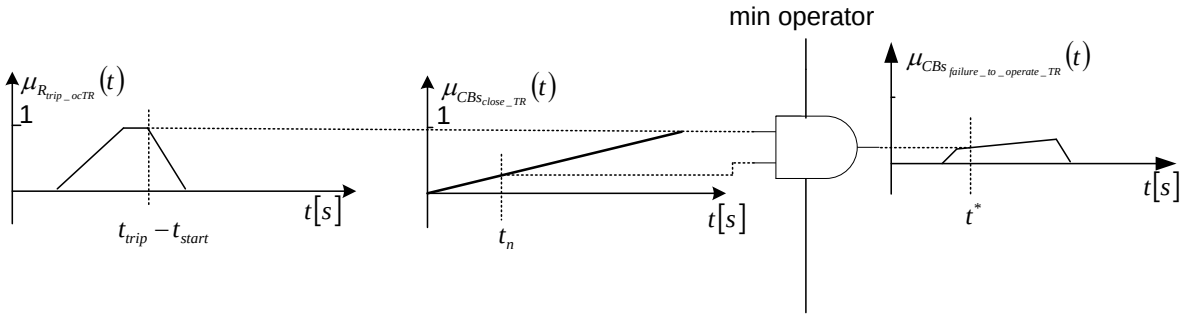
c) Krivo djelovanje oba prekidača transformatora

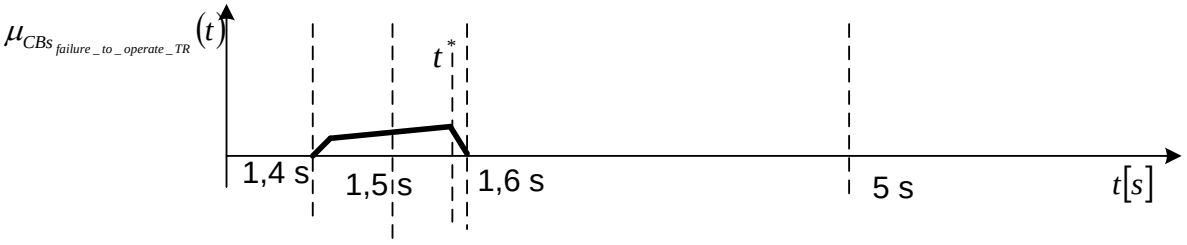




$$t^* = \frac{\int_{1.44}^{1.47}(10t-14.4)tdt + \int_{1.47}^{5}0.2t^2dt}{\int_{1.44}^{1.47}(10t-14.4)tdt + \int_{1.47}^{5}0.2tdt} = 3.52 \rightarrow \mu(t^*) = 0.704$$

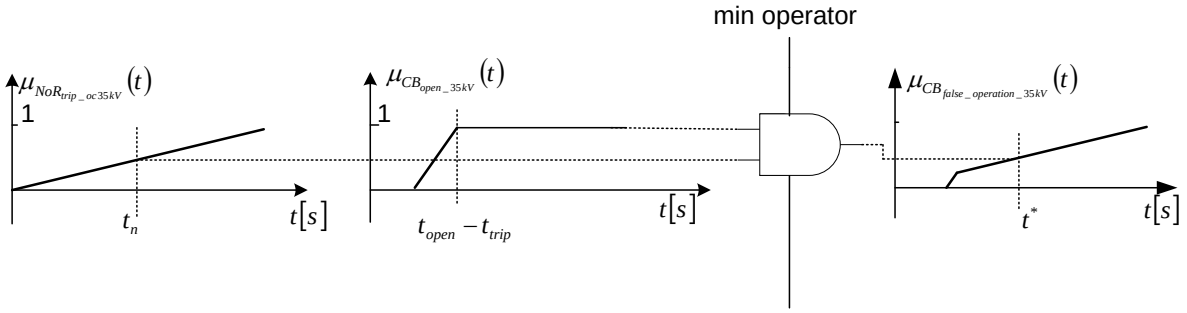
e) Otkazivanje djelovanja oba prekidača na transformatoru

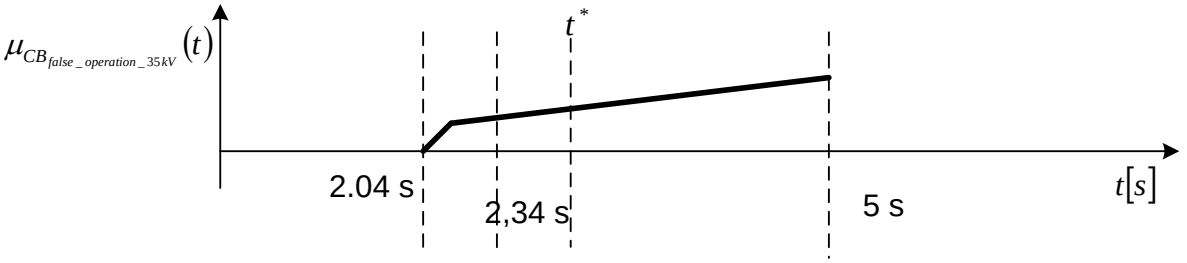




$$\mu(1.58) = 0.316$$

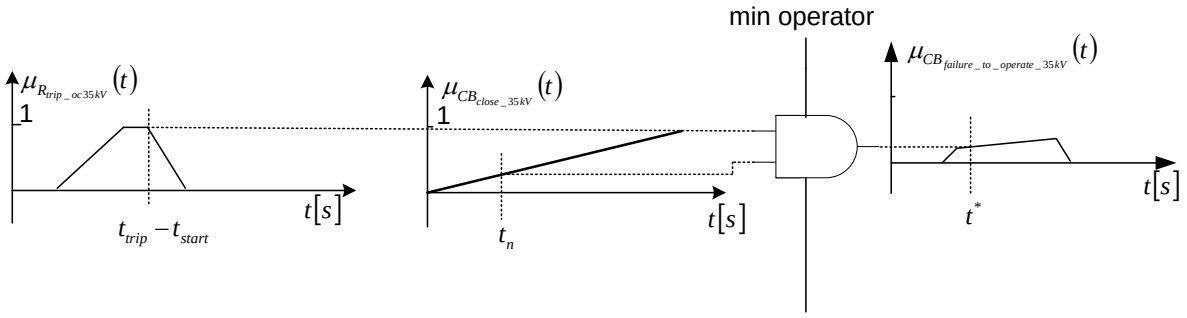
f) Krivo djelovanje prekidača na dalekovodu 35 kV

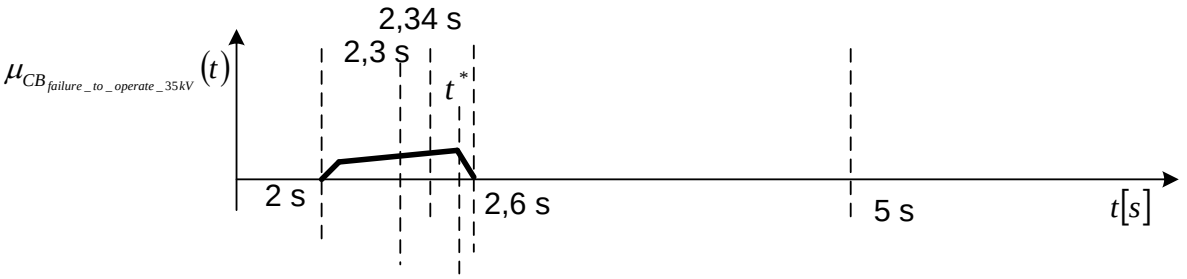




$$t^* = \frac{\int_{2.04}^{2.17}(3.34t-6.67)tdt + \int_{2.17}^{5}0.2t^2dt}{\int_{2.04}^{2.17}(3.34t-6.67)dt + \int_{2.17}^{5}0.2tdt} = 3.73 \rightarrow \mu(t^*) = 0.746$$

g) Otkazivanje djelovanja prekidača na dalekovodu 35 kV

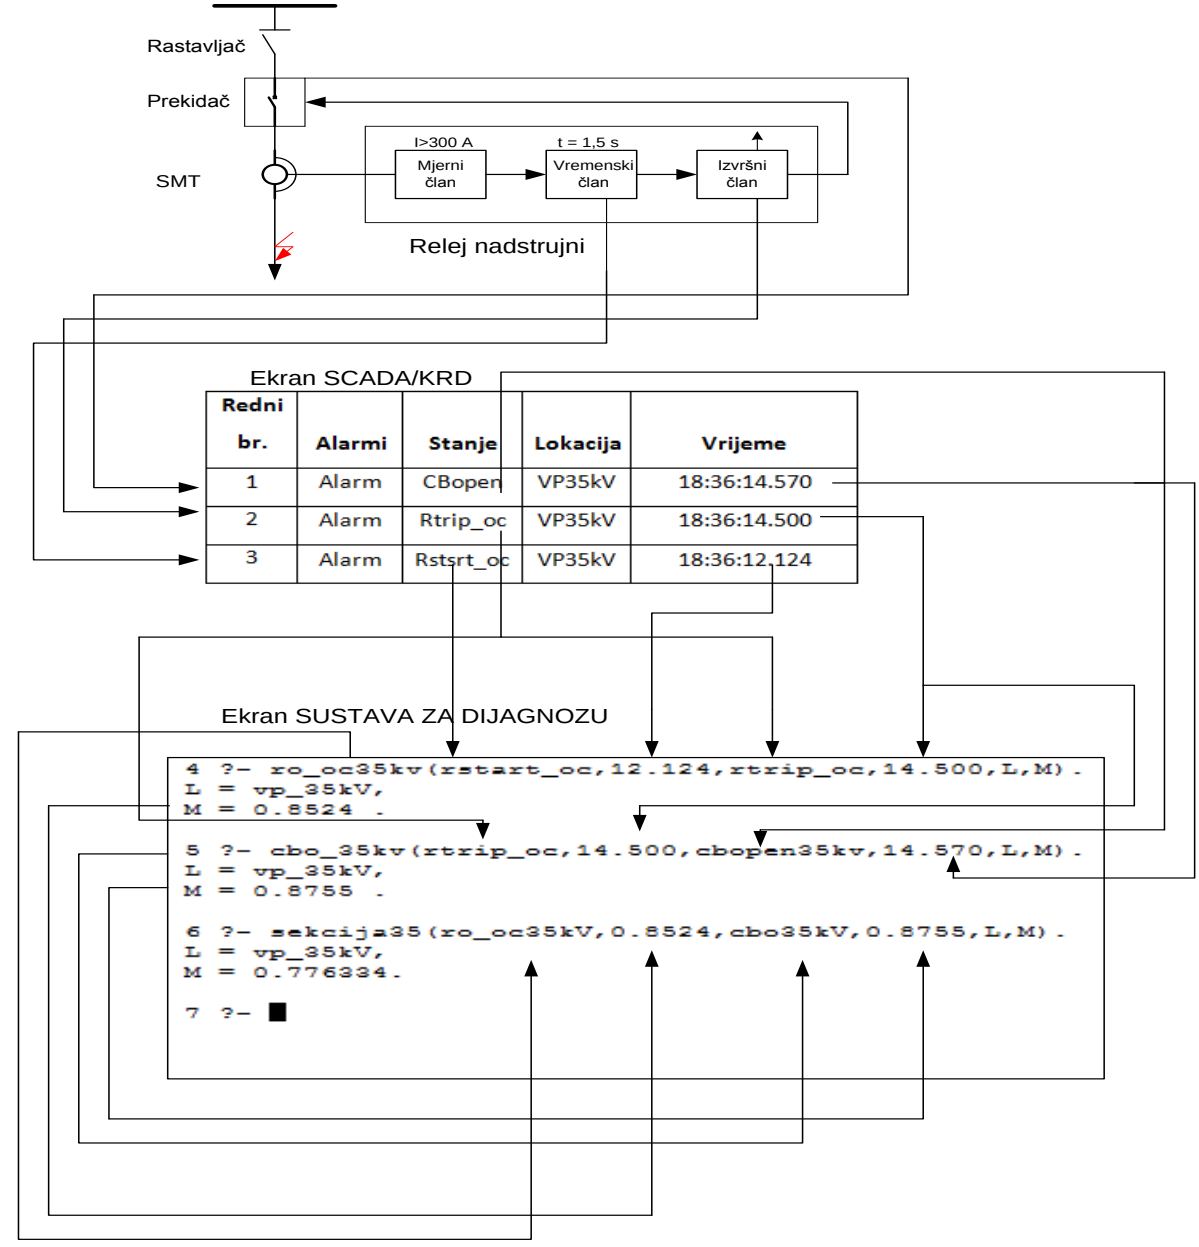


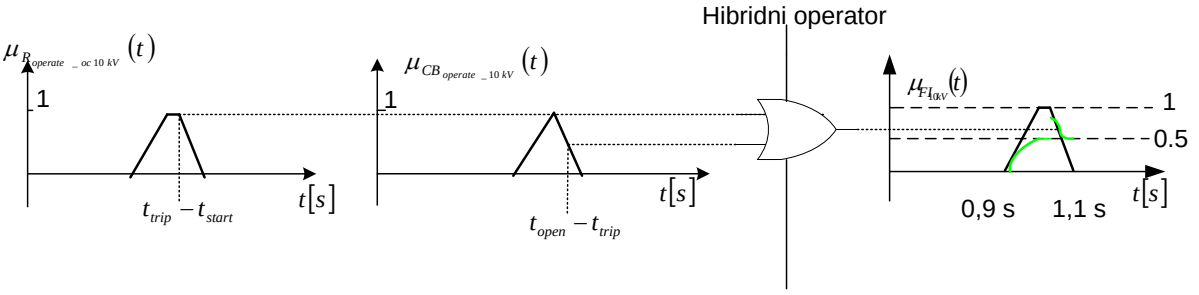


$\mu(2.47) = 0.494$

Dodatak C.

Slučaj1:





Slučaj 2:

```
19 ?- ro_oc10kv(rstart_oc,12.252,rtrip_oc,12.880,L,M).
false.

20 ?- rfo_oc10kv(rstart_oc,12.252,rtrip_oc,12.880,L,M).
L = vp_10kV,
M = 0.80724 .

21 ?- cbo_10kv(rtrip_oc,12.880,cbopen10kv,12.930,L,M).
L = vp_10kV,
M = 0.8365 .

22 ?- sekcija10(rfo_oc10kV,0.80724,cbo10kV,0.8365,L,M).
L = vp_10kV,
M = 0.771676.

23 ?-
```

Slučaj 3:

```
12 ?- ro_oc35kv(rstart_oc,10.010,rtrip_oc,12.310,L,M).
L = vp_35kV,
M = 1 .

13 ?- cbo_35kv(rtrip_oc,12.310,cbopen35kv,12.340,L,M).
L = vp_35kV,
M = 0.9822 .

14 ?- sekcija35(ro_oc35kV,1,cbo35kV,0.9822,L,M).
L = vp_35kV,
M = 0.5.

15 ?- ro_octr(rstart_oc,10.011,rtrip_oc,11.520,L,M).
L = tr_polje1,
M = 1 .

16 ?- cbso_tr(rtrip_oc,11.520,cbs_open_tr,11.545,L,M).
L = tr_polje1,
M = 0.85 .

17 ?- sekcijatr(ro_octr,1,cbso_tr,0.85,L,M).
L = tr_polje1,
M = 0.5 .

18 ?- sekcija35_tr(vp35kv,0.5,transformator,0.5,M,L).
M = 0.5,
L = simultani_kvar_VP35kV_i_transformator.

19 ?-
```

Slučaj 4:

```
8 ?- cbfo_10kV(nortrip_oc,cbopen10kv,16.156,L,M).
L = vp_10kV,
M = 0.682 .

9 ?-
```

Slučaj 5:

```
4 ?- rfto_sc35kv(rstart_sc,17.129,nortrip_sc,L,M).
L = vp_35kV,
M = 0.67.

5 ?-
```

Slučaj 6:

```
6 ?- cbfto_10kv(rtrip_oc,28.124,cbclose_10kv,L,M).
L = vp_10kV,
M = 0.218 .

7 ?-
```

Slučaj 7:

```
10 ?- ro_oc35kv(rstart_oc,15.426,rtrip_oc,17.8,L,M).
L = vp_35kV,
M = 0.8601 .

11 ?- cbo_10kv(rtrip_oc,16.432,cbopen10kv,16.450,L,M).
L = vp_10kV,
M = 0.78 .

12 ?- cbsfo_tr(nortrip_oc,cbs_open_tr,17.000,L,M).
L = tr_polje1,
M = 0.704 .

13 ?-
```

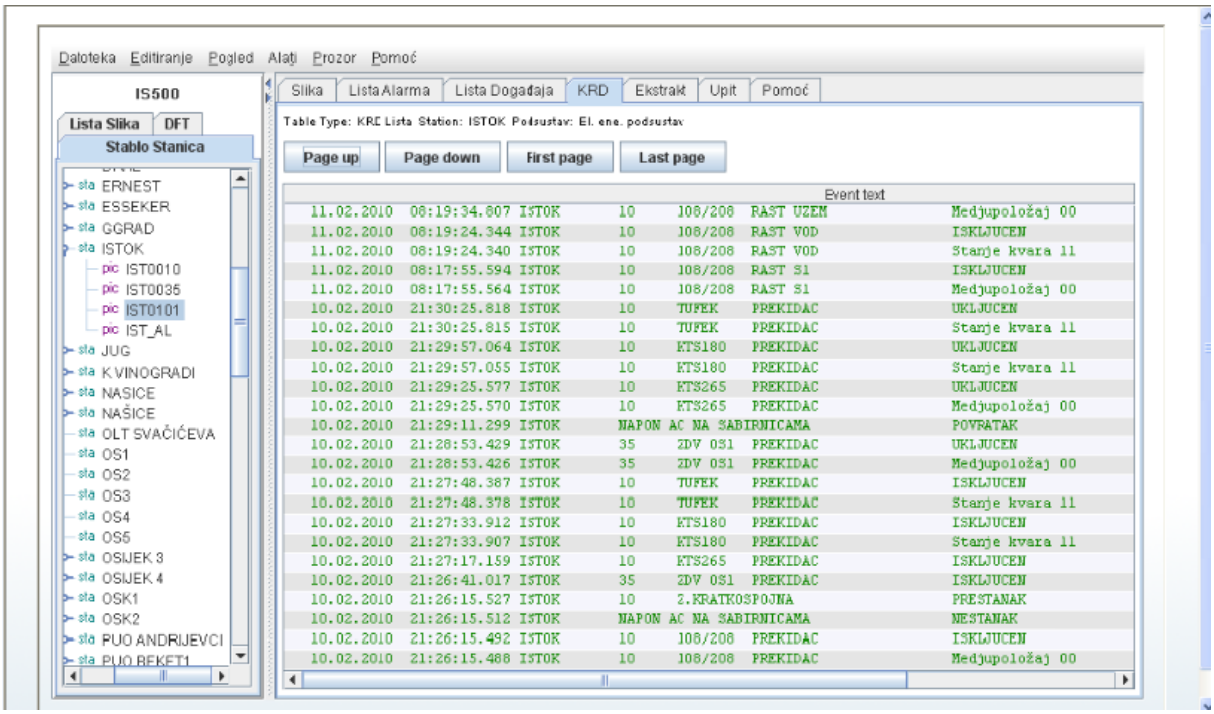
Slučaj 8:

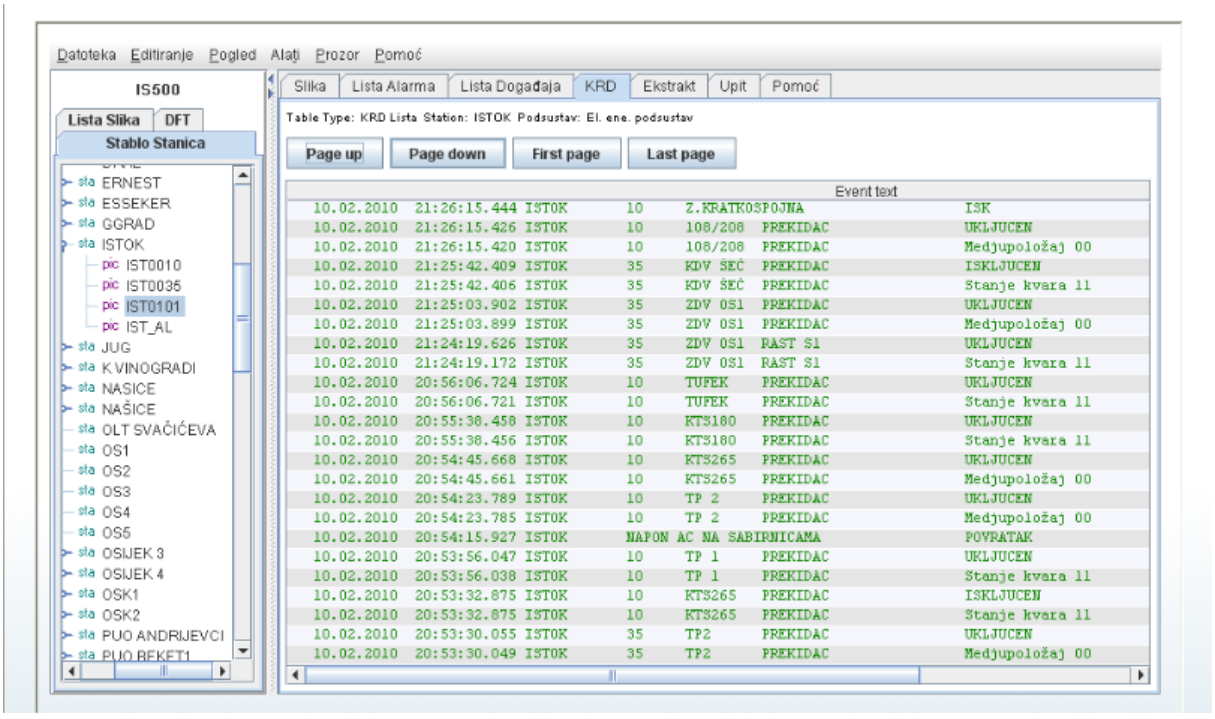
```
2 ?- cbo_108_208(rtrip_sc,14.901,cbopen_108_208,14.948,L,M).
L = vp_10kV_KTS_108_208,
M = 0.88792 .

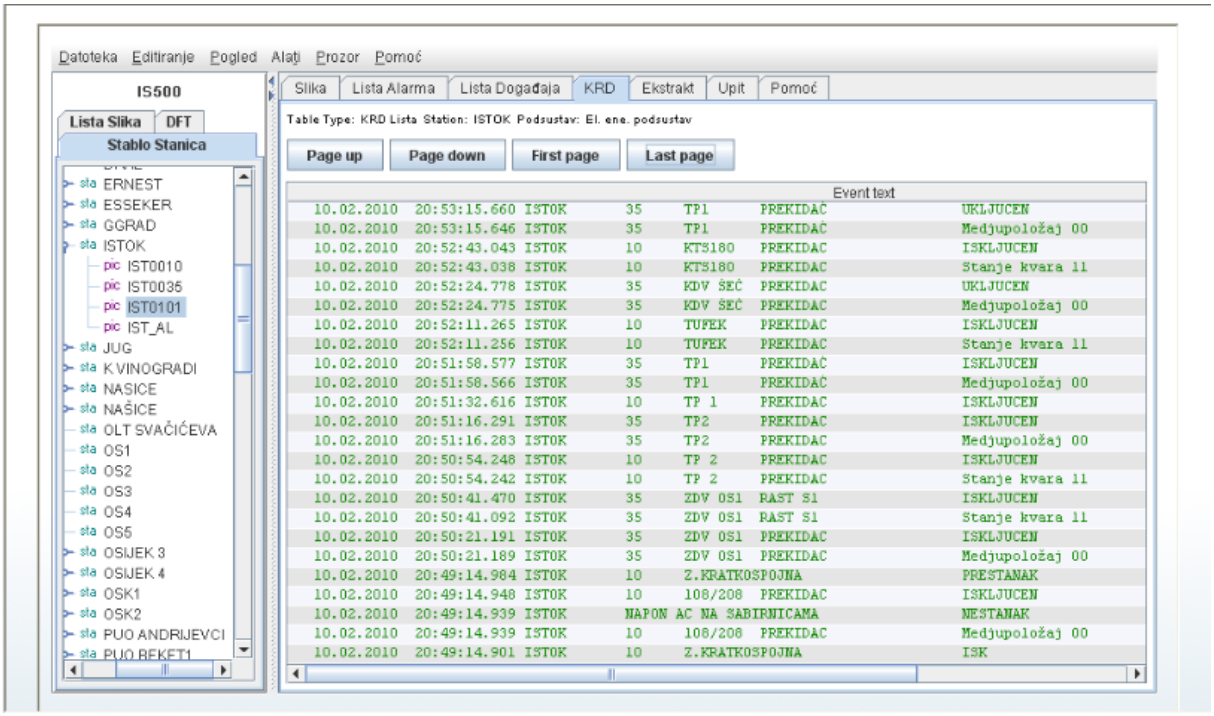
3 ?- cbo_35kv(rtrip_sc,15.206,cbopen35kv,15.266,L,M).
L = vp_35kV,
M = 0.6796.

4 ?-
```

Dodatak D: Originalni alarmi






Datoteka Editiranje Pogled Alati Prozor Pomoć
IS500
Lista Slika
DFT
Stablo Stanica
sta ERNEST
sta ESSEKER
sta GGRAD
sta ISTOK
pic IST0010
pic IST0035
pic IST0101
pic IST_AL
sta JUG
sta K.VINOGRADI
sta NASICE
sta NAŠICE
sta OLT SVAČIĆEVA
sta OS1
sta OS2
sta OS3
sta OS4
sta OS5
sta OSIJEK 3
sta OSIJEK 4
sta OSK1
sta OSK2
sta PUO ANDRIJEVCI
sta PUO BEKET1
Slika
Lista Alarma
Lista Događaja
KRD
Ekstrakt
Upit
Pomoć
Table Type: KRD Lista Station: ISTOK Podsustav: El. ene. podsustav
Page up
Page down
First page
Last page
Event text
10.02.2010 20:53:15.660 ISTOK 35 TP1 PREKIDAC UKLJUCEN
10.02.2010 20:53:15.646 ISTOK 35 TP1 PREKIDAC Medjupoložaj 00
10.02.2010 20:52:43.043 ISTOK 10 KTS180 PREKIDAC ISKLJUCEN
10.02.2010 20:52:43.038 ISTOK 10 KTS180 PREKIDAC Stanje kvara 11
10.02.2010 20:52:24.778 ISTOK 35 KDV ŠEĆ PREKIDAC UKLJUCEN
10.02.2010 20:52:24.775 ISTOK 35 KDV ŠEĆ PREKIDAC Medjupoložaj 00
10.02.2010 20:52:11.265 ISTOK 10 TUFEK PREKIDAC ISKLJUCEN
10.02.2010 20:52:11.256 ISTOK 10 TUFEK PREKIDAC Stanje kvara 11
10.02.2010 20:51:58.577 ISTOK 35 TP1 PREKIDAC ISKLJUCEN
10.02.2010 20:51:58.566 ISTOK 35 TP1 PREKIDAC Medjupoložaj 00
10.02.2010 20:51:32.616 ISTOK 10 TP 1 PREKIDAC ISKLJUCEN
10.02.2010 20:51:16.291 ISTOK 35 TP2 PREKIDAC ISKLJUCEN
10.02.2010 20:51:16.283 ISTOK 35 TP2 PREKIDAC Medjupoložaj 00
10.02.2010 20:50:54.248 ISTOK 10 TP 2 PREKIDAC ISKLJUCEN
10.02.2010 20:50:54.242 ISTOK 10 TP 2 PREKIDAC Stanje kvara 11
10.02.2010 20:50:41.470 ISTOK 35 ZDV OS1 RAST S1 ISKLJUCEN
10.02.2010 20:50:41.092 ISTOK 35 ZDV OS1 RAST S1 Stanje kvara 11
10.02.2010 20:50:21.191 ISTOK 35 ZDV OS1 PREKIDAC ISKLJUCEN
10.02.2010 20:50:21.189 ISTOK 35 ZDV OS1 PREKIDAC Medjupoložaj 00
10.02.2010 20:49:14.984 ISTOK 10 Z.KRATKOSPOJNA PRESTANAK
10.02.2010 20:49:14.948 ISTOK 10 108/208 PREKIDAC ISKLJUCEN
10.02.2010 20:49:14.939 ISTOK NAPON AC NA SABIRNICAMA NESTANAK
10.02.2010 20:49:14.939 ISTOK 10 108/208 PREKIDAC Medjupoložaj 00
10.02.2010 20:49:14.901 ISTOK 10 Z.KRATKOSPOJNA ISK

POPIS SLIKA

Slika 4.1: Osnovni ekspertni sustav……30

Slika 4.2: Proces ljudskog razmišljanja……...31

Slika 4.3: Ekspertni sustav s pripadajućim cjelinama…….31

Slika 4.4: Zaključivanje unaprijed……..34

Slika 4.5: Zaključivanje unatrag…….35

Slika 5.1: Sugeno model neizrazitog ekspertnog sustava……..…….39

Slika 5.2: Mamdani model neizrazitog ekspertnog sustava..……..40

Slika 5.3: Model nepostojeće informacije……...43

Slika 6.1: Strujno vremenske karakteristike releja……..46

Slika 6.2: Idealna funkcionalna djelovanja releja promatrana u vremenu……..47

Slika 6.3: Vremenska pogreška releja…….47

Slika 6.4: Realno ispravno djelovanje releja promatrano u vremenu…….48

Slika 6.5: Krivo djelovanje releja promatrano u vremenu……..49

Slika 6.6: Usporedni prikaz stanja releja i prekidača pomoću klasičnog i fuzzy skupa kod ispravnog djelovanja nadstrujnog releja i prekidača……...52

Slika 6.7: Dio 35 kV mreže Elektroslavonije……..55

Slika 6.8: Funkcije pripadnosti u odnosu ispravnog djelovanja nadstrujnog releja…….56

Slika 6.9: Funkcija pripadnosti krivog djelovanja nadstrujnog releja na dalekovodu 10 kV……....57

Slika 6.10: Funkcija pripadnosti krivog djelovanja nadstrujnog releja koji štiti dalekovod 10 kV……..58

Slika 6.11: Funkcija pripadnosti otkazivanja djelovanja nadstrujnog releja koji štiti dalekovod 10 kV……..59

Slika 6.12: Funkcije pripadnosti djelovanja, krivog djelovanja i otkazivanja djelovanja nadstrujnog releja koji štiti dalekovodu 10 kV……59

Slika 6.13: Funkcija pripadnosti ispravnog djelovanja kratkospojnog releja koji štiti dalekovod 10 kV……..60

Slika 6.14: Funkcija pripadnosti krivog djelovanja kratkospojnog releja koji štiti dalekovod 10 kV…….61

Slika 6.15: Funkcije pripadnosti otkazivanja djelovanja kratkospojnog releja koji štiti dionicu dalekovoda 10 kV……62

Slika 6.16: Funkcije pripadnosti ispravnog djelovanja, krivog djelovanja i otkazivanja djelovanja kratkospojnog releja koji štiti dionicu dalekovoda 10 kV……..62

Slika 6.17: Funkcije pripadnosti ispravnog djelovanja zemljospojnog releja koji štiti dionicu dalekovoda 10 kV……63

Slika 6.18: Funkcije pripadnosti krivog djelovanja zemljospojnog releja koji štiti dalekovod 10 kV……64

Slika 6.19: Funkcije pripadnosti otkazivanja djelovanja zemljospojnog releja koji štiti dalekovod 10 kV …….65

Slika 6.20: Funkcije pripadnosti ispravnog djelovanja, krivog i otkazivanja djelovanja zemljospojnog releja koji štiti dalekovod 10 kV…….66

Slika 6.21: Funkcije pripadnosti ispravnog djelovanja nadstrujnog releja koji štiti transformator……66

Slika 6.22: Funkcija pripadnosti krivog djelovanja nadstrujnog releja koji štiti transformator……67

Slika 6.23: Funkcija pripadnosti krivog djelovanja nadstrujnog releja koji štiti transformator…….....68

Slika 6.24: Funkcije pripadnosti otkazivanje djelovanja nadstrujnog releja koji štiti transformator……..…..69

Slika 6.25: Funkcije pripadnosti ispravnog djelovanja kratkospojnog releja koji štiti dalekovod 35 kV……..70

Slika 6.26: Funkcije pripadnosti krivog djelovanja kratkospojnog releja koji štiti dalekovod 35 kV…….71

Slika 6.27: Funkcije pripadnosti otkazivanja djelovanja kratkospojnog releja koji štiti dalekovod 35 kV……..72

Slika 6.28: Funkcija pripadnosti ispravnog djelovanja nadstrujnog releja koji štiti dalekovod 35 kV……73

Slika 6.29: Funkcije pripadnosti krivog djelovanja nadstrujnog releja koji štiti dalekovod 35 kV…….74

Slika 6.30: Funkcija pripadnosti otkazivanja djelovanja nadstrujnog releja koji štiti dalekovod 35 kV……75

Slika 6.31: Funkcije pripadnosti ispravnog djelovanja zemljospojnog releja koji štiti dalekovod 35 kV……..76

Slika 6.32: Funkcije pripadnosti krivog djelovanja zemljospojnog releja koji štiti dalekovod 35 kV……77

Slika 6.33: Funkcije pripadnosti u odnosu na vrijeme kod otkazivanja djelovanja zemljospojnog releja ……...78

Slika 6.34: Funkcija pripadnosti ispravnog djelovanja prekidača dalekovoda 10 kV……..81

Slika 6.35: Funkcija pripadnosti krivog djelovanja prekidača dalekovoda 10 kV……...82

Slika 6.36: Funkcija pripadnosti otkazivanje djelovanja prekidača dalekovoda 10 kV……...83

Slika 6.37: Funkcija pripadnosti ispravnog djelovanja oba prekidača transformatora…….84

Slika 6.38: Funkcija pripadnosti krivog djelovanja oba prekidača transformatora……..85

Slika 6.39: Funkcija pripadnosti otkazivanje djelovanja oba prekidača transformatora……..86

Slika 6.40: Funkcija pripadnosti ispravnog djelovanja prekidača dalekovoda 35 kV…….….87

Slika 6.41: Funkcija pripadnosti krivog djelovanja prekidača dalekovoda 35 kV……..88

Slika 6.42: Funkcija pripadnosti otkazivanje djelovanja prekidača dalekovoda 35 kV……..89

Slika 6.43: Funkcija pripadnosti lokacije kvara na dalekovodu 10 kV……...90

Slika 6.44: Funkcija pripadnosti lokacije kvara na dalekovodu 10 kV……...91

Slika 6.45: Funkcija pripadnosti lokacije kvara na transformatorskom polju…….92

Slika 6.46: Funkcija pripadnosti lokacije kvara na dalekovodu 35 kV……...93

Slika 6.47: Funkcija pripadnosti kvara na dalekovodu 10 kV i dalekovodu 35 kV……....94

Slika 6.48: Funkcija pripadnosti za simultani kvar na dalekovodu 10 kV i transformatorskom polju……...……..95

Slika 6.49: Funkcija pripadnosti za simultani kvar na transformatorskom polju i dalekovodu 35 kV……95

Slika 6.50: Sagitalni dijagram stanja (alarma) za dalekovod 10 kV……98

Slika 6.51: Sagitalni dijagram alarma za transformatorsko polje……...100

Slika 6.52: Sagitalni dijagram alarma za dalekovod 35 kV……102

Slika 7.1: Identifikacija kvara za slučaj I ……..104

Slika 7.2: Identifikacija kvara za slučaj II…….……..106

Slika 7.3: Identificirani kvarovi za slučaj III…….…..108

Slika 7.4: Identificiran kvar za slučaj IV…….....109

Slika 7.5: Identificiran kvar za slučaj V……..111

Slika 7.6: Identificiran kvar za slučaj VI…….112

Slika 7.7: Identificirani kvarovi za slučaj VII…….114

Slika 7.8: Alarmi s KRD-a za slučaj VIII…….……....117

Slika 7.9: Identificirani kvarovi na distribucijskoj mreži za slučaj VIII……...118

POPIS TABLICA

Tablica 3.1: Usporedba pojedinih metoda……28

Tablica 7.1: Alarmi slučaj I……..…103

Tablica 7.2: Dijagnoza I…….……103

Tablica 7.3: Alarmi na KRD-u nakon poremećaja za slučaj II……...…104

Tablica 7.4: Dijagnoza za slučaj II……..105

Tablica 7.5: Alarmi za slučaj III……...……...106

Tablica 7.6: Dijagnoza kvara za slučaj III……...…...……107

Tablica 7.7: Alarmi na KRD-u za slučaj IV……...……108

Tablica 7.8: Rezultati dijagnoze za slučaj IV……...……...109

Tablica 7.9: Alarmi koji su se pojavili na KRD-u za slučaj V……110

Tablica 7.10: Rezultati dijagnoze za slučaj V……110

Tablica 7.11: Alarmi na KRD-u za slučaj VI……...……...111

Tablica 7.12: Rezultati dijagnoze za slučaj VI……...……112

Tablica 7.13: Alarmi prikazani na KRD-u za slučaj VII……...……...113

Tablica 7.14: Rezultati dijagnoze za slučaj VII……...…….114

Tablica 7.15: Rezultati dijagnoze kod slučaja VIII…….……118

SAŽETAK

U doktorskoj disertaciji razvijen je neizraziti ekspertni sustav (off-line) za dijagnozu kvara u distributivnoj mreži na bazi strukturalnog i funkcionalnog djelovanja releja i prekidača. Prikazan je novi način modeliranja funkcionalnog djelovanja releja i prekidača koji je opisan pomoću neizrazite logike. Neizrazita logika (više-vrijednosna logika) je metoda koja se bavi modeliranjem nepreciznosti, nesigurnosti kod donošenja odluka. Poboljšava i povećava potencijal kod modeliranja ljudskog razmišljanja koje koristi lingvističke varijable. Neizrazita logika (teorija) je u suprotnosti s klasičnom teorijom vjerojatnosti, jer je prva deterministička, a druga stohastička u naravi. Teorija vjerojatnosti se koristi bi-vrijednosnom logikom (0 ili 1), dok neizrazita teorija može poprimiti bilo koju vrijednost između 0 i 1. Neizrazita logika nudi jednostavan pristup modeliranju nejasnih, neprecizni, izobličeni i nepostojećih ulaznih informacija. Neizraziti dijagnostički sustav kao ulazne podatke koristi statuse releja i prekidača te njihove vremenske oznake. Dijagnostički sustav iz ogromnog broja alarma postavlja, logički organizira i kvantificira dijagnoze. Razvijeni dijagnostički sustav za dijagnozu kvara uspješno dijagnosticira djelovanje, krivo djelovanje i otkazivanje djelovanja releja i prekidača. Također ima mogućnost lociranja (identificiranja) kvara te njegovog kvantificiranja na bazi hibridnog operatora unije koji je iskazan kao aritmetička sredina Hamackerovog i Schweizerovog operatora unije. Pored navedenog uspješno se nosi i s kvarovima telemetrije koristeći novi način modeliranja nepostojećih informacija pomoću linearne funkcije pripadnost u odnosu na vrijeme.

Ključne riječi: dijagnoza kvara, procesiranje alarma, neizrazita logika, neizraziti ekspertni sustavi.

SUMMARY

In this doctoral dissertation was developed off-line fuzzy expert system for fault diagnosis in distribution network based on the structural and functional operation of relays and circuit breakers. Functional operation of relays and circuit breakers is described by fuzzy logic as a new way of modeling. Fuzzy logic (multiple-value logic) is a method that deals with the modeling of imprecision, uncertainty in decision-making process. It improves and increases the potential in the modeling of human thinking which uses linguistic variables. Fuzzy logic (theory) is in contrast with the classical theory of probability, since the first is deterministic and the other is stochastic in nature. Probability theory uses bi-value logic (0 or 1), while fuzzy theory can take any value between 0 and 1. Fuzzy logic offers a simple approach for modeling vague, inaccurate, distorted and missing informations. Imput information of fuzzy diagnostic system are the status of relays and circuit breakers and their time stamps. Diagnostic system logically organize and quantifie diagnosis from the huge alarm streams.Operation, false operation and failure of operation for circuit brakers and realays can be diagnosed with the developed diagnostic system. Fault location (identification) is quantified with hybrid union operator which is discribed as the arithmetic mean of Hamackers and Schweizers operator. New method of modeling the missng information as linear membership functions with respect to time is used for dealing with failures of telemetry.

Key words: fault diagnosis, alarm processing, fuzzy logic, fuzzy expert systems.

ŽIVOTOPIS

Rođen sam 21. srpnja 1983. godine u Osijeku. Pohađao sam osnovnu školu Ivana Filipovića u Osijeku od 1990. do 1998. godine. Nakon završene osnovne škole upisujem srednju Elektrotehničku i prometnu školu u Osijeku. Srednju Elektrotehničku i prometnu školu u Osijeku završio sam 2002. godine i stekao zvanje elektrotehničara. Elektrotehnički fakultet u Osijeku općeg smjera upisao sam 2002. godine. Diplomirao sam na Elektrotehničkom fakultetu u Osijeku 2007. godine i stekao zvanje diplomiranog inženjera elektrotehnike smjer energetika. Nakon završenog fakulteta 2007. godine počinjem radit u HEP-Operator distribucijskog sustava d.o.o. "Elektroslavoniji Osijek" (Služba za vođenje; Odjelu za zaštitu i mjerenje). Prvenstveno sam radio na poslovima zaštite (primarnim i sekundarnim ispitivanjima), funkcionalnim ispitivanjima i puštanjima opreme u pogon. Poslijediplomski studij elektrotehnike smjer elektroenergetika upisao sam 2008. godine na Elektrotehničkom fakultetu u Osijeku u vidu stjecanja akademskog stupnja doktora znanosti. Od 2010. godine prelazim u Službu za održavanje u odjel za tehnološku pripremu i razvoj te se bavim sanacijama naponskih prilika. Kao autor objavio sam četiri rada od čega tri u časopisu A kategorije. Član sam međunarodne IEEE organizacije sa sjedištem u SAD. Kvalifikacijski doktorski ispit na Elektrotehničkom fakultetu u Osijeku položio sam 2012. godine. U ured Službe za održavanje prelazim 2013. godine. Sredinom 2013. godine prelazim u Službu za razvoj i investicije gdje se trenutno nalazim. Javni razgovor sam obavio 2014. godine u vidu prhvaćanja teme disertacije.