

METODE ZA OPTIMALNO PLANIRANJE SN RAZDJELNIH MREŽA

SAŽETAK

Opisane su osnovne faze i značajke planiranja srednjenaponskih (SN) elektroenergetskih razdjelnih mreža. Naglašen je utjecaj dobrog planiranja na smanjenje ukupnih troškova razdjelne mreže. Definiran je odgovarajući matematički model planiranja i prikazana njegova struktura. Pokazano je kako opseg elemenata koje obuhvaća model i stupanj detalja kojim su prezentirani utječe na složenost optimizacijskog problema i odabir odgovarajuće metode rješavanja. S obzirom da problem optimalnog planiranja SN razdjelne mreže predstavlja sa stanovišta rješavanja složen problem, primjena točnih metoda je ograničena na mreže malih dimenzija. Zato je naglasak dan na prezentiranje aproksimativnih metoda kao što su stohastička relaksacija, genetski algoritam i nedozvoljeno pretraživanje. Dan je pregled nekih programskih paketa za optimalno planiranje. Istaknut je značaj stalnog usavršavanja postojećih programa i metoda optimiranja.

Ključne riječi: Srednjenaponska razdjelna mreža, planiranje, optimizacijske metode

METHODS FOR OPTIMAL MV POWER DISTRIBUTION PLANNING

SUMMARY

The main phases and characteristics of medium voltage (MV) power distribution network planning are described. The impact of well-directed planning on the reduction of total network costs is emphasized. The appropriate mathematical planning model and its structure are defined. It is demonstrated what impact the quantity of model elements and exactness of their presentation has on the optimization problem complexity and on choice of an adequate solving method. Given the fact that, in the light of computational complexity, the optimal MV network planning falls into the class of hard problems, the application of the exact methods is limited to small-size cases. For this reason the presentation of approximate methods such as simulated annealing, genetic algorithm and tabu search is emphasized. The review of some professional software packages for optimal planning is given. The importance of permanent improvements of the existing software and optimization methods is underlined.

Key words: MV power distribution network, planning, optimization methods

1. UVOD

U referatu su prezentirane osnovne značajke planiranja srednjenaponskih (SN) elektroenergetskih razdjelnih mreža. Definirani su potrebni podaci, energetske i troškovne funkcije elemenata mreže, struktura modela za planiranje mreže i metode rješavanja. Opisane su najvažnije značajke pogonskog i kratkoročnog planiranja mreže a naglasak je dan na dugoročno planiranje.

Rezultati analize postojeće mreže i konzuma te prognoza budućeg opterećenja predstavljaju polaznu točku za planiranje. U tu svrhu ukratko su opisane metode prognoziranja opterećenja te mogućnost primjene neizrazite logike u toj problematici ali i šire u elektroenergetskom sustavu.

Koristeći energetske i troškovne karakteristike vodova i transformatorskih stanica, definiran je model planiranja mreže. Cilj planiranja je izgraditi takvu mrežu da se osigura opskrba potrošača električnom energijom propisane kvalitete uz najmanje ukupne troškove. Razvoj računala i matematičkih postupaka omogućili su primjenu optimizacijskih metoda kojima planeri mogu doći rješenja zahtijevane kakvoće. Modeli za planiranje mreža se razlikuju po opsegu elemenata koje obuhvaćaju i stupnju preciznosti prikaza, a što ima izravnih posljedica na njihovu matematičku strukturu i primjenu odgovarajućih metoda optimizacije. U ovom radu su u svom elementarnom obliku opisane i ilustrirane neke tipične metode optimizacije koje se koriste u planiranju razdjelnih mreža. Osim toga, radi se o općenitim algoritmima koji, između ostalih područja primjene, imaju široku upotrebu i u rješavanju drugih problema vezanih za elektroenergetski sustav.

Dan je prikaz nekih programskih paketa za planiranje razdjelnih mreža. Navedena su iskustva iz hrvatske prakse te ukazano na realizaciju neophodnih pretpostavki za njihovu djelotvorniju primjenu.

2. OSNOVNE ZNAČAJKE I FAZE PLANIRANJA

2.1. Aspekti planiranja i potrebne podloge

Planirati SN razdjelnu mrežu znači predvidjeti i definirati plan ukupnih aktivnosti vezanih uz strukturu i pogon mreže kao bi svi potrošači bili opskrbljeni električnom energijom zahtijevane kvalitete uz najmanje troškove.

Prema ciljevima, učincima i vremenu provedbe planiranje može biti:

- a) pogonsko (operativno)
- b) kratkoročno
- c) dugoročno.


Za razliku od kratkoročnog i dugoročnog planiranja, u pogonskom planiranju osnovna konfiguracija mreže je definirana tj. nema izgradnje novih niti rekonstrukcije postojećih napojnih transformatorskih stanica i vodova.

Svako planiranje se zasniva na analizi postojeće mreže te na karakteristikama i prognozi konzuma. Na slici 1. su shematski prikazani najvažniji elementi i međusobne veze u procesu planiranja.

Analiza postojeće mreže je polazna točka za sve vrste planiranja odnosno njihov je sastavni dio.

Da bi se planiranje i pogon razdjelne mreže moglo realizirati na djelotvoran i ekonomičan način važno je imati potpune, ažurne i pristupačne podatke. Međutim, priprema i obrada podataka predstavlja značajan problem. Prvo, svi potrebni podaci se ne nalaze u istoj bazi podataka nego u različitim kao npr. u *informacijskom sustavu potrošača CIS (Customer Information System)*, *grafičkim bazama AM/FM (Automated Mapping and Facility Management)* ili u *bazama daljinskog upravljanja SCADA (Supervision, Control And Data Acquisition)*. Drugo, podaci u originalnim bazama ne moraju biti u istoj formi u kojoj je zahtijevaju analitički aplikacijski programi, nego ih treba prirediti na odgovarajući način. Treće, zato jer su različite baze međusobno odvojene, svaka od njih prezentira distributivni sustav u drugačijem stanju pa prije nego što se kombiniraju njihovi podaci posebno im treba ispitati integritet [42].

Grafički sustavi AM/FM, bazirani na alatima kompjutorskog crtanja CAD (*Computer Aided Design*) su se dugo koristili u distributivnim poduzećima, a njihov najveći nedostatak je bio pomanjkanje relacijske baze podataka. Neki CAD alati osiguravaju ograničenu vezu s vanjskim bazama podataka, ali nezadovoljavaju u drugim aspektima kao što su integritet podataka i normiranje baze podataka. Od 1980. pojavila se nova generacija grafičkih softvera nazvanih *geografski informacijski sustavi (GIS)*. Osnovna razlika između GIS-a i CAD-a je što prvi omogućuje izgradnju relacijskih baza podataka, implicitno mrežno modeliranje i raznolikost prostornih funkcija. Radi toga su mnoga distributivna poduzeća počela koristiti GIS za kreiranje svojih grafičkih baza podataka. Takvi sustavi se uobičajeno zovu AM/FM/GIS.



Slika 1. Proces planiranja SN razdjelne mreže

U užem smislu riječi pod planiranjem razdjelne mreže se podrazumijeva dugoročno planiranje. Ova aplikacija kao i niz drugih zamišljene su da se vežu na GIS. Međutim, do stupnja realizacije GIS-a primjerenog za aktivnu podršku ovim metodama, u sklopu programskih paketa za planiranje razvijene su pomoćne baze podataka i grafički načini prikaza elemenata mreže.

2.2. Pogonsko planiranje

Pogonsko ili operativno planiranje obuhvaća planiranje aktivnosti kojima se poboljšava rad mreže u okvirima osnovne aktualne izgrađenosti odnosno postojećeg broja transformatorskih stanica i vodova.

Tu se mogu ubrojiti određivanje optimalnog:

- uklopnog stanja mreže
- razmještaja i veličine kondenzatorskih baterija
- broja i vrste rastavnih uređaja itd.

Određivanjem optimalnog uklopnog stanja postiže se minimum radnih gubitaka u mreži.

Optimalnim razmještajem kondenzatorskih baterija polučuju se najbolji ekonomski učinci radi:

- povećanja propusnosti elemenata mreže
- smanjenja radnih gubitaka
- poboljšanja naponskih prilika.

Definiranjem optimalnih tipova, broja i razmještaja rastavnih uređaja u mreži postiže se najpovoljniji odnos između troškova i vrijednosti pouzdanosti.

Troškovi pouzdanosti predstavljaju potrebna ulaganja u sustav da se postigne zahtijevana razina pouzdanosti, a novčana korist koju ostvaruju dobavljač i potrošači električne energije od takvih ulaganja se zove *vrijednost pouzdanosti* [6,18,35].

Dok su metode za određivanje troškova pouzdanosti odnosno troškova elektroenergetskog sustava vezanih za postizanje zahtijevane razine pouzdanosti u potpunosti razvijene i prihvaćene, postupci za procjenu vrijednosti pouzdanosti još uvijek nisu. Zato se u svrhu utvrđivanja vrijednosti pouzdanosti kao praktična i sve više korištena metoda upotrebljava procjena posljedica prekida napajanja potrošača električnom energijom tj. procjena troškova neisporučene električne energije.

2.3. Kratkoročno planiranje

Kratkoročni planovi razvoja se temelje na smjernicama dugoročnog planiranja, a definiraju zahvate koje je potrebno neposredno provesti i zato najčešće obuhvaćaju razdoblje od 5 godina što se podudara s neophodnim periodom pripreme i izgradnje predviđenih vodova i napojnih trafostanica.

2.4. Dugoročno planiranje

Dugoročnim planiranjem SN razdjelnih mreža ili planiranjem u užem smislu stvaraju se pretpostavke za donošenje odluka o takvoj izgradnji novih i rekonstrukciji postojećih napojnih transformatorskih stanica i srednjenaponskih vodova da se osigura opskrba potrošača električnom energijom propisane kvalitete uz najmanje ukupne troškove. Da bi se postigla kvalitetna opskrba odnosno kontinuirano napajanje potrošača naponom određenog iznosa, valnog oblika i frekvencije moraju biti zadovoljena ograničenja s obzirom na dozvoljene padove napona i termička opterećenja elemenata mreže. Pouzdanost se uzima u obzir posredno preko unaprijed zadane strukture mreže ili neposredno razmatranjem troškova neisporučene električne energije. Ukupni troškovi mreže obuhvaćaju troškove investicija, održavanja, gubitaka radne snage i energije te, ako se pouzdanost eksplicitno uzima u obzir, neisporučene električne energije. Obično obuhvaća period od 20 godina.

3. PROGNOZA OPTEREĆENJA

3.1. Prognoza opterećenja malih područja

Razmještaj, veličina i vrijeme pojave točaka opterećenja su ulazni podaci za proces planiranja i trebaju biti unaprijed poznati. To znači da moraju biti raspoloživi rezultati prognoze opterećenja koji se odnose na porast tereta u postojećim te na opterećenje u novim transformatorskim stanicama 10(20)/0.4 kV uključujući i njihove lokacije.

Prostorna prognoza opterećenja (spatial load forecast) predviđa mjesto (što je jedno od njenih glavnih obilježja), veličinu i vrijeme pojave opterećenja. Usko je vezana uz pojam *mala područja (small area)* [36,43,44].

Mala područja se definiraju kao područja opskrbe nekog dijela distribucijskog sustava (npr. transformatorske stanice ili napojnog voda), koja su obično nepravilnog oblika i nejednake veličine, ili kao mreža kvadrata.

Za dobro prognoziranje važno je odabrati pravu veličinu malog područja jer su opterećenje i njegove promjene unutar malog područja uprosječene i detaljnije varijacije se ne mogu uočiti. Minimalna rezolucija odnosno najveća veličina malog područja koja još uvijek daje dovoljno podataka za potrebe planiranja može se odrediti prostornom frekvencijskom analizom [43]. Pri određivanju mjesta i veličine točaka opterećenja razdjelnih mreža kao praktičan kriterij za izbor veličine malog područja može se uzeti zahtjev da ne smije biti više od jedne transformatorske stanice 10(20)/0.4 kV po malom području.

Razvoj opterećenja u malim područjima obilježen je nelinearnim dinamičkim porastom od nule do približno 80% konačnog iznosa u svega nekoliko godina, a najbolje se opisuje tzv. *“S” krivuljom*. Ova krivulja pripada kategoriji prirodnih ili bioloških krivulja jer se mnogi procesi u prirodi odvijaju upravo po tim zakonitostima. Krivulju karakterizira lagani rast u početnom razdoblju, značajniji i dinamičan porast u sredini razdoblja, te postupno približavanje nekoj asimptotskoj vrijednosti (zasićenju). *“S”* krivulje se najčešće opisuju logističkim ili Gompertzovim zakonom porasta.

3.2. Primjena neizrazite logike u prognoziranju opterećenja

3.2.1. Neizrazite varijable i skupovi

Teoriju *neizrazitih skupova* (*fuzzy sets*) osmislio je profesor računarstva Lotfi A. Zadeh sa Sveučilišta Berkeley u Kaliforniji 1965. godine, a za rješavanje problema u elektroenergetici prvi put je primijenjena 1979. godine.

Primjena teorije neizrazitih skupova zasnovane na *neizrazitoj logici* (*fuzzy logic*) omogućuje stvaranje jednostavnih ali djelotvornih *neizrazitih modela* (*fuzzy models*) za opisivanje i rješavanje mnogih složenih problema, posebno onih nepoznate strukture, parametara i njihovih promjena. Tehnika neizrazite logike je općenito prikladna za korištenje u situacijama koje karakterizira nepreciznost, dvosmislenost i neizvjesnost [7,22].

Neka su X i A klasični skupovi takvi da je A proizvoljni podskup od X . U tom se slučaju skup A može precizno opisati *binarnom karakterističnom funkcijom* $f_A: X \rightarrow \{0,1\}$ definiranom kao:


$$f_A(x) = \begin{cases} 1, & \text{ako je } x \in A \\ 0, & \text{u protivnom} \end{cases}$$

Za razliku od elemenata klasičnih skupova, čija je pripadnost ili nepripadnost skupu nedvojbeno, elemente neizrazitih skupova karakterizira kontinuirani stupanj članstva, od nepripadanja do potpune pripadnosti skupu.

Ako je A neizraziti podskup od X , može se definirati *funkcijom pripadnosti* (*membership function*) ili *vjerodostojnosti* (*truth function*) $\mu_A: X \rightarrow [0,1]$ koja pokazuje s kolikim stupnjem pripadnosti je element $x \in X$ član neizrazitog podskupa A . Taj stupanj može biti $\mu_A(x)=0$, $0 < \mu_A(x) < 1$ i $\mu_A(x)=1$ odnosno funkcija pripadnosti je normirana u rasponu od 0 do 1.

Za tehnike neizrazitog modeliranja ključna je ideja *neizrazitih* (*fuzzy*) ili *jezičnih* (*linguistic*) *varijabli* (*variables*). Varijabla se naziva neizrazita jer poprima vrijednosti iz neizrazitog skupa ili jezična jer simbolizira ime neizrazitog skupa odnosno njegova je semantička oznaka.

Kao i klasični, i neizraziti skup služi za formaliziranje određenog pojma ili zamisli. Na slici 2. je prikazana neizrazita varijabla **VISOK** odnosno neizraziti skup **VISOK** kojim se želi opisati jakost veze između pojedinca, s obzirom na njegovu visinu, i skupa visokih osoba.




Slika 2. Primjer neizrazitog skupa

Pojam **VISOK** je tipičan primjer neizrazitog skupa i ilustrira prirodna svojstva neizrazitog prostora. Funkcija pripadnosti se interpretira kao mjera kompatibilnosti između vrijednosti iz domene i pojma (u ovom slučaju **VISOK**) koji čini osnovu neizrazitog skupa. Kako se vrijednost funkcije pripadnosti kreće prema nuli, razmatrani slučaj postaje sve manje i manje kompatibilan sa semantičkom oznakom (u ovom slučaju **VISOK**), a kako se vrijednost funkcije pripadnosti kreće prema 1, razmatrani slučaj postaje sve više i više kompatibilan sa semantičkom oznakom odnosno svojstvom neizrazitog skupa.

Oblik ili *vanjšina* (*surface*) neizrazitog skupa može imati različitu formu. Osnovne krivulje odnosno oblici neizrazitih skupova koji se upotrebljavaju u neizrazitim modelima su linearni oblik, S-krivulja, zvonolike krivulje, trokutasti i trapezoidni skupovi. Neizraziti skupovi zvonolikog oblika predstavljaju važnu klasu krivulja jer se koriste za prikaz *neizrazitih brojeva* (*fuzzy numbers*) i neizrazitih prostora koji se šire oko središnje, centralne vrijednosti. Neizraziti brojevi predstavljaju aproksimaciju neke vrijednosti i obično pružaju bolji radni skup nego odgovarajuća *izrazita* (*crisp*) vrijednost. Postoje tri važne klase zvonolikih krivulja, a to su π , β i Gaussova krivulja. Iako zvonolike krivulje vjernije opisuju pojedine neizrazite skupove, dosta se koriste i trokutasti oblici jer su jednostavniji.

Za razliku od vjerojatnosti koja se odnosi na raspodjelu učestalosti u slučajnom uzorku, neizrazita logika opisuje same osobine odnosno svojstva koja imaju kontinuirano promjenjive veličine tako da tim svojstvima pridružuje dijelove ovih veličina sa semantičkom oznakom. Najveći dio opisne moći neizrazite logike proizlazi iz činjenice da se ovi semantički dijelovi mogu preklapati. Neizrazite varijable za sobom povlače i koncept *kvalifikatora neizrazitih skupova* (*fuzzy set qualifiers*) koji mijenjaju oblik neizrazitog skupa na predvidljiv način i funkcioniraju jednako kao pridjevi i prilozi u jeziku.

Neizrazita logika, u svjetlu teorije neizrazitih skupova, pruža osnovu za stvaranje i pisanje *neizrazitih modela* (*fuzzy models*). Neizrazita varijabla modela je često opisana pomoću *prostora neizrazitosti* (*fuzzy space*). Prostor se općenito sastoji od više međusobno preklapajućih neizrazitih skupova, a koji svaki opisuju semantičku particiju dozvoljenog stanja varijable. Npr. parametar modela odnosno varijabla **TEMPERATURA** se može podijeliti na 5 neizrazitih skupova: **SMRZNUTO**, **HLADNO**, **NORMALNO**, **TOPLO** i **VRUĆE**, kao što je prikazano na slici 3. Ovaj ukupni prostor problema, od najmanje do najveće vrijednosti, zove se *područje definicije* (*universe of discourse*). Područje definicije je pridruženo varijabli modela, a ne pojedinom neizrazitom skupu (raspon pojedinog neizrazitog skupa je domena). Kolekcija svih neizrazitih skupova pridruženih varijabli često se zove *terminski skup* (*term set*).



TEMPERATURA - neizrazita varijabla
HLADNO, **TOPLO**, **NORMALNO**,
TOPLO, **VRUĆE** - neizraziti skupovi
 $[-10, 5]$, $[-5, 15]$, $[5, 25]$,
 $[15, 35]$, $[25, 40]$ - domene skupova
 $[-10, 40]$ - područje definicije
 $\mu(x)$ - funkcija pripadnosti

Slika 3. Područje definicije neizrazite varijable **TEMPERATURA**

Određivanje broja i oblika neizrazitih skupova odnosno funkcija pripadnosti nije strogo definirano, subjektivno je te ovisi o vrsti i poznavanju problema koji se želi riješiti.

3.2.2. Neizrazito modeliranje

Osnovni mehanizam u izgradnji *neizrazitih modela* odnosno *neizrazitih sustava zaključivanja* (*fuzzy reasoning systems*) je *pravilo* (*rule*) ili *tvrdnja* (*proposition*), a slična je pravilu u konvencionalnim ekspertnim sustavima. Pravila su iskazi o vezama između ulaznih i izlaznih neizrazitih varijabli modela. Forma pravila je npr. "ako je $x \in A$ (premissa ili uvjet 1) i $y \in B$ (premissa ili uvjet 2) onda je $z \in C$ (zaključak ili posljedica)", gdje su x , y i z ulazne i izlazne neizrazite varijable, a A , B i C odgovarajući neizraziti ulazni i izlazni skupovi. Kako pojedine ulazne varijable mogu imati različiti stupanj pripadnosti svojim neizrazitim skupovima odnosno različite vrijednosti funkcija pripadnosti, treba formalizirati njihov utjecaj na vrijednost zaključka odnosno funkciju pripadnosti izlazne varijable. Utvrđivanje funkcionalne veze između stupnjeva

pripadnosti među razmatranim neizrazitim skupovima vrši se *metodom implikacije (method of implication)*. Uspostavljanje funkcionalne veze između neizrazitih područja i očekivane izrazite, konkretne vrijednosti skupa rješenja vrši se *metodom pretvorbe u izrazite vrijednosti (defuzzification)* ili *dekompozicije (decomposition)*. Metode implikacije i dekompozicije čine osnovu neizrazitog zaključivanja.

Pravila zaključivanja su često prikazana *tablicom pravila neizrazitog zaključivanja FAM (Fuzzy Associative Memory)*.

Bazna i najjednostavnija implicitna neizrazita tehnika je *monotono zaključivanje (monotonic reasoning)*, a metode koje primjenjuju složenija pravila zaključivanja su *min-max metoda (min-max method)* i *metoda dodavanja (additive method)* [7].

Min-max metodom se najprije primjenom određenog pravila aktivira izlazni (posljedični) neizraziti skup (npr. primjenom nekog pravila P1 koje glasi “*ako je $x \in A_1$ i $y \in B_1$ onda je $z \in C_1$* ” aktivira se izlazni neizraziti skup C_1). Zatim se taj izlazni neizraziti skup modificira prema iznosu funkcije pripadnosti one premise ili uvjeta u pravilu koja ima najmanju vrijednost funkcije (npr. u slučaju pravila P1 funkcija pripadnosti izlazne varijable ima vrijednost $\mu_{C_1}(z_i) = \min\{\mu_{A_1}(x), \mu_{B_1}(y)\}$ za $\forall z_i \in C_1$). Na isti način se odrede modificirani izlazni neizraziti skupovi za sva razmatrana pravila. Zajednički izlazni skup svih pravila dobije se kao unija svih izlaznih skupova dobivenih primjenom pojedinih pravila (npr. u slučaju primjene m pravila funkcija pripadnosti ukupnog izlaznog neizrazitog skupa $C = \{C_1 \cup C_2 \cup \dots \cup C_m\}$ jednaka je $\mu_C(z_i) = \max[\mu_{C_1}(x_i), \mu_{C_2}(x_i), \dots, \mu_{C_m}(x_i)]$ za $\forall z_i \in C$).

Metoda dodavanja se neznatno razlikuje od min-max metode [7].

Da se nađe konkretna, izrazita izlazna varijabla odnosno iznos odgovarajućeg skalara mora se odrediti vrijednost koja najbolje prezentira informaciju sadržanu u neizrazitom izlaznom skupu. Zato treba primijeniti metodu pretvorbe u izrazite vrijednosti ili metodu dekompozicije koja predstavlja završnu fazu neizrazitog zaključivanja.

Dvije najčešće metode dekompozicije su *metoda težišta (composite moments – centroid)* i *metoda maksimalne vrijednosti (composite maximum)*.

Npr. metoda težišta traži “ravnotežnu” točku neizrazitog izlaznog skupa ili područja rješenja računanjem težišne sredine neizrazitog područja. Aritmetički, za neizrazito područje rješenja C ova točka se računa kao $\sum_{i \in C} \mu_C(z_i) z_i / \sum_{i \in C} \mu_C(z_i)$.

Prema tome, proces neizrazitog modeliranja ili zaključivanja odvija se u nekoliko faza. Prva faza predstavlja pretvorbu ulaznih podataka u neizrazite vrijednosti formiranjem odgovarajućih neizrazitih skupova i funkcija pripadnosti. U drugoj fazi se na osnovi iskustveno definiranih pravila, metodom implikacije provodi neizrazito zaključivanje odnosno određivanje neizrazitog skupa rješenja. U završnoj fazi se metodom dekompozicije vrši pretvorba neizrazite u izrazitu izlaznu veličinu.

3.2.3. Primjer određivanja normativa opterećenja kućanstva

Ilustrirana je jednostavna primjena neizrazitog modeliranja pri utvrđivanju normativa opterećenja pojedinog kućanstva u malom području ovisno o tome je li provedena plinifikacija te postoji li centralizirani toplinski sustav (CTS).

U tu svrhu su najprije definirani odgovarajući ulazni i izlazni neizraziti skupovi odnosno varijable.

Ulazna neizrazita (jezična) varijabla modela **UTJECAJ CTS-a (X)** koja opisuje kakav učinak ima planirana godina dovršenja izgradnje CTS-a na normativ opterećenja kućanstva u malom području podijeljena je na 5 neizrazitih skupova **VRLO VELIKI (VV)**, **VELIKI (V)**, **UMJERENI (U)**, **MALI (M)** i **VRLO MALI (VM)**. Kao što se vidi na slici 4., na isti način je definirana i druga ulazna neizrazita varijabla **UTJECAJ PLINA (Y)**. Očito je da je utjecaj CTS-a ili plinifikacije na normativ potrošnje velik, ako oni već postoje ili se planiraju ubrzo realizirati.

Izlazna neizrazita varijabla **TIP NORMATIVA (Z)** također se sastoji od 5 neizrazitih skupova **VRLO MALI NORMATIV (VMN)**, **MALI NORMATIV (MN)**, **SREDNJI NORMATIV (SN)**, **VELIKI NORMATIV (VN)** i **VRLO VELIKI NORMATIV (VVN)**.


Tablica 1. predstavlja tablicu pravila neizrazitog zaključivanja FAM za razmatrani primjer.

Ako npr. varijable **UTJECAJ CTS-a** i **UTJECAJ PLINA** poprimaju vrijednosti iz neizrazitih skupova **VRLO VELIKI (VV)**, onda je izlazna varijabla, prema tablici pravila neizrazitog zaključivanja, definirana na neizrazitom skupu **VRLO MALI NORMATIV (VMN)**. Naime, kako u tom slučaju CTS ili plinifikacija već postoje ili se namjeravaju ostvariti u samom početku perioda prognozanja, električna energija se neće trošiti na grijanje, pripremu tople vode i djelomično na kuhanje, pa treba računati s malim normativom potrošnje.

Tablica I. Tablica pravila neizrazitog zaključivanja

		UTJECAJ CTS – a				
		VV	V	U	M	VM
U T J E C A	P	VV	VMN	VMN	MN	MN
	L	V	VMN	MN	SN	SN
	I	U	MN	MN	SN	VN
	N	M	MN	SN	SN	VN
	A	VM	MN	SN	VN	VN

Situacija je potpuno suprotna, ako varijable **UTJECAJ CTS-a** i **UTJECAJ PLINA** poprimaju vrijednosti iz neizrazitih skupova **VRLO MALI (VM)** pa je izlazna varijabla, prema pravilu neizrazitog zaključivanja, definirana na neizrazitom skupu **VRLO VELIKI NORMATIV (VVN)**. Radi se o slučaju kada će se CTS ili plinifikacija realizirati pri samom kraju perioda prognoziranja ili se uopće neće provesti pa će se električna energija koristiti za sve namjene u kućanstvu, što ima za posljedicu razmatranje vrlo velikog normativa potrošnje. Unutar ovih granica, tablicom pravila neizrazitog zaključivanja, obuhvaćeni su ostali mogući slučajevi.



Slika 4. Grafički prikaz neizrazitog modeliranja utjecaja planirane godine izgradnje CTS-a i plinifikacije na vrijednost normativa opterećenja kućanstva u malom području

Neka se u 4. godini planira izgraditi CTS, a u 15. godini izvršiti plinifikacija. U tom slučaju ulazna varijabla **UTJECAJ CTS-a** odnosno **X** poprima vrijednosti iz neizrazitih podskupova **VRLO VELIKI (VV)** i **VELIKI (V)**, a ulazna varijabla **UTJECAJ PLINA** odnosno **Y** iz skupa **MALI (M)**. Zato se aktiviraju dva pravila zaključivanja koja prema tablici neizrazitog zaključivanja glase: “**ako je $x \in V$ i $y \in M$ onda je $z \in SN$** ” (P1) i “**ako je $x \in VV$ i $y \in M$ onda je $z \in MN$** ” (P2). Procesuiranjem ova dva pravila primjenom min-max metode implikacije dobije se modificirani izlazni neizraziti skup kakav je prikazan na slici 4. Konačno, korištenjem metode težišta kao metode dekompozicije dobivena je izrazita, jedinstvena vrijednost izlazne varijable $z=4,6$ kW.

3.2.4. Mogućnosti primjene neizrazite logike u drugim područjima ees-a

Iscrpan pregled literature u kojoj su primjenom neizrazite logike obrađeni i riješeni različiti problemi u elektroenergetskom sustavu dan je u [5].

Ovdje su navedena neka od potencijalnih područja primjene neizrazite logike u elektroenergetskom sustavu:

- prognoza opterećenja
- optimalni tokovi snaga
- planiranje ees-a
- dijagnostika kvarova
- ponovno uspostavljanje napajanja
- vrednovanje pouzdanosti ees-a
- određivanje rasporeda rada generatora
- određivanje rasporeda održavanja generatora
- zaštita ees-a
- regulacija jalove snage i napona
- analiza stabilnosti itd.

4. MODEL PLANIRANJA SN RAZDJELNE MREŽE

4.1. Osnovne karakteristike elemenata mreže

Ključni elementi koji se uzimaju u obzir pri planiranju srednjenaponske razdjelne mreže i njenoj tehnokonomskoj analizi su napojne transformatorske stanice i srednjenaponski vodovi. Opisani su tehničkim karakteristikama te troškovima investicija, održavanja i gubitaka.

4.1.1. Gubici radne snage i energije

Utjecaj gubitaka radne snage i energije u elektroenergetskom sustavu odnosno njihov troškovni ekvivalent je značajan tako da bi svako planiranje koje ih ne uvažava bilo nepotpuno.

Prema svojstvima, energetske gubici se mogu podijeliti na stalne i promjenjive. Stalni gubici se javljaju čim je neki element u pogonu i ne ovise o opterećenju (gubici u željezu transformatora, gubici zbog korone i odvoda preko izolatora kod dalekovoda, dielektrični gubici kod kabela i kondenzatora itd.). Promjenjivi gubici ovise o opterećenju i mijenjaju se s kvadratom jakosti struje opterećenja, a ispoljavaju se kao omski toplinski gubici. Smanjenje promjenjivih gubitaka je jedan od zadataka pri planiranju elektroenergetskih mreža te ih je zato potrebno što preciznije matematički prikazati.

U svakom elementu trofaznog sustava javljaju se gubici radne snage koji su predstavljeni izrazom:

$$\Delta P = 3I^2 R = \frac{R}{U^2 \cos \varphi} P^2 \quad (1)$$

R4

gdje su:

- ΔP - gubici radne snage [W]
- I - jakost struje kroz element [A]
- R - radni otpor elementa [Ω]
- P - radna snaga [W]
- U - linijski napon [V]

$\cos \varphi$ - faktor snage.

Gubici radne energije se mogu iskazati kao:

$$\Delta W = \Delta P \cdot T_{\Delta} \quad (2)$$

gdje su:

- ΔW - gubici energije u promatranom vremenu [Wh]
- T_{Δ} - godišnje vrijeme trajanja gubitaka [h].

Vrijednost veličine T_{Δ} najčešće se određuje preko T_m . Relacija koja se odnosi na nekakav tipizirani konzum i koja je prilično široko prihvaćena glasi [30]:

$$T_{\Delta} = 0.17 T_m + 0.83 \frac{T_m^2}{8760} \quad (3)$$

gdje je:

- T_m - godišnje vrijeme trajanje vršnog opterećenja [h].

4.1.2. Troškovi voda

Svaki element razdjelne mreže je, pored topoloških i tehničkih podataka kao što su lokacija, napon, snaga, presjeci vodova i sl., opisan i s troškovnim karakteristikama. Troškove transformatorskih stanica i vodova čine troškovi investicija, održavanja te troškovi gubitaka radne snage i energije. Ovi troškovi se mogu podijeliti na fiksne i varijabilne. Fiksni troškovi su konstantni i javljaju se čim je neki element ugrađen dok varijabilni ovise o opterećenju razmatranog elementa.


Fiksne troškove vodova čine troškovi investicija i troškovi održavanja, koji se obično izražavaju u postocima investicija, dok se varijabilni troškovi vodova sastoje od troškova gubitaka radne snage i energije. Svi troškovi se uzimaju aktualizirano. Ukupni troškovi voda po jedinici duljine T_v mogu se prikazati slijedećom relacijom [32,34]:

$$T_v = a + b \cdot P^2 \quad [\text{kn/km}] \quad (4)$$

gdje su:

- a - fiksni troškovi voda po jedinici duljine [kn/km]
- b - varijabilni troškovi voda po jedinici duljine i kvadratu prenesene snage [kn/km·W²]
- P - radna snaga koja protječe vodom [W].

Jedna tipična troškovna karakteristika voda prikazana je na slici 5.



Slika 5. Kvalitativni prikaz troškovne karakteristike SN voda

Da bi se izbjegla vezanost za određenu vrstu presjeka i tip vodiča te ovisnost o kvadratu prenesene snage obično se izraz (4) zamjenjuje aproksimativnim:

$$T'_v = a' + b' \cdot P \quad [\text{kn/km}] \quad (5)$$

gdje su:

- a' - prosječni fiksni troškovi voda po jedinici duljine [kn/km]
- b' - linearizirani varijabilni troškovi voda po jedinici duljine i prenesenoj snazi [kn/km·W].

4.1.3. Troškovi transformatorske stanice

Fiksni troškovi transformatorskih stanica se sastoje od troškova investicija, održavanja i gubitaka u željezu transformatora, dok gubici u bakru transformatora čine varijabilne troškove. Ukupni troškovi transformatorske stanice mogu se prikazati izrazom [32,34]:

$$T_t = c + d \cdot P^2 \quad [\text{kn}] \quad (6)$$

gdje su:

- c - fiksni troškovi transformatorske stanice [kn]
- d - varijabilni troškovi transformatorske stanice po kvadratu prenesene snage [kn/W²].

Nakon linearne aproksimacije dobiva se izraz (7):

$$T'_t = c' + d' \cdot P \quad [\text{kn}] \quad (7)$$

gdje su:

c' - prosječni fiksni troškovi transformatorske stanice [kn]

d' - linearizirani varijabilni troškovi transformatorske stanice po jedinici prenesene snage [kn/W].

Za potpuniju ocjenu troškova transformatorske stanice potrebno je znati i njene troškove priključka na prijenosnu mrežu pa se definiraju prošireni troškovi napojne transformatorske stanice koji uključuju i troškove priključnog voda duljine l :

$$T''_t = T'_v \cdot l + T'_t = (a' \cdot l + c') + (b' \cdot l + d') \cdot P = c'' + d'' \cdot P \quad [\text{kn}] \quad (8)$$

4.2. Ciljevi i kriteriji planiranja

Cilj planiranja razdjelne mreže je odrediti takve nazivne snage i lokacije napojnih transformatorskih stanica te trase i presjeke srednjenaponskih vodova da svi potrošači budu opskrbljeni potrebnom snagom uz najmanje troškove i ispunjenje svih tehničkih uvjeta. Pod tehničkim uvjetima se podrazumijevaju dozvoljeni padovi napona i opterećenja elemenata mreže. Pouzdanost se uzima u obzir posredno, preko unaprijed zadane strukture mreže, ili neposredno, valoriziranjem troškova neisporučene električne energije.

Ukupni troškovi koji se minimiziraju obuhvaćaju:

- a) fiksne troškove napojnih transformatorskih stanica
 - troškovi investicija
 - troškovi održavanja
 - troškovi radnih gubitaka u željezu transformatora
- b) varijabilne troškove transformatorskih stanica
 - troškovi radnih gubitaka u bakru transformatora
- c) fiksne troškove SN vodova
 - troškovi investicija
 - troškovi održavanja
- d) varijabilne troškove SN vodova
 - troškovi radnih gubitaka
- e) ovisno o strukturi mreže, troškove prekida napajanja tj. pouzdanosti mreže.

Pojedini tipovi mreža (gradska, prigradska, pokrajinska) imaju različite oblike konfiguracija SN vodova, a što je prije svega posljedica drugačije gustoće opterećenja (ali i značaja potrošača). Gradske mreže su prostorno zamkaste. Najprepoznatljivije zamkaste strukture su prstenasta i povezna. Pokrajinske (seoske, ruralne) mreže su uglavnom prostorno radijalne. Kod gradskih i pokrajinskih mreža pouzdanost je zadana strukturom mreže, pa se razmatra kao kriterij odnosno ograničenje koje unaprijed treba zadovoljiti. Pri tome je evidentno, s obzirom na veliki utjecaj rezervnog napajanja na pouzdanost u slučaju kvara neke od dionica SN vodova, da su gradske mreže znatno pouzdanije. Međutim, kod prigradskih mreža odnosno prijelaznih prostornih struktura između zamkastih i radijalnih mreža treba razmotriti međusobni utjecaj povećanja troškova radi izgradnje poveznih (spojnih) vodova i smanjenja troškova neisporučene električne energije zbog rezervnog napajanja koje ti vodovi omogućuju. I to je najčešći slučaj kada se pouzdanost eksplicitno razmatra pri planiranju razdjelne mreže odnosno tretira kao varijabla.

Osnovni kriteriji koji moraju biti zadovoljeni pri planiranju su:

- a) nazivna opterećenja
 - transformatora
 - vodova
- b) padovi napona u čvorovima
- c) razina pouzdanosti
 - kriterij $n-1$ za napojne trafostanice
 - struktura mreže (gradske i pokrajinske mreže).

4.3. Matematički opis modela

Matematička forma modela za optimalno planiranje srednjenaponskih razdjelnih mreža ovisi o mnogim utjecajima kao što su:

- opseg mreže koji se želi obuhvatiti
- oblik i struktura mreže
- stupanj detalja koji se želi modelirati
- uvažavanje postojećeg stanja izgrađenosti
- način uzimanja u obzir vremenske komponente
- modeliranje samo napojnih transformatorskih stanica, samo vodova ili oboje
- uzimanje u obzir samo fiksnih troškova, varijabilnih troškova ili oboje
- točno ili aproksimativno modeliranje pojedinih funkcijskih ovisnosti
- razina razmatranja pouzdanosti
- uzimanje u obzir troškova neisporučene električne energije
- neizvjesnosti razvoja opterećenja itd.

Tako se npr. model mreže koji obuhvaća i napojne transformatorske stanice i vodove, opisane fiksnim i varijabilnim troškovima, naziva *potpuni* model, a inače je *nepotpun*. Model koji uvažava vremensku komponentu je *dinamički*, za razliku od *statičkog*, dok *pseudodinamički* pristup karakterizira višestruka primjena statičkog modela u cilju vremenskog sagledavanja procesa planiranja.


Nakon što je postavljen model mreže, problem se rješava matematičkim postupcima koji mogu biti *točni* ili *aproksimativni*. Pri tome se ova tvrdnja, osim na glavne postupke rješavanja problema, odnosi i na pojedine module (potprograme) koji se koriste u okviru optimizacijskog procesa (npr. na algoritme za računanje tokova snaga).

Svaki *optimizacijski problem* se sastoji od *funkcije cilja*, čiji se maksimum ili minimum traži, te *ograničenja* koja se moraju zadovoljiti.

Primjer modela za optimalno planiranje srednjenaponskih razdjelnih mreža grafički je predložen na slici 6.

Funkcija cilja za problem određivanja optimalnih lokacija i nazivnih snaga napojnih transformatorskih stanica te trasa i presjeka srednjenaponskih vodova može se formulirati na slijedeći način:

$$\min \left[\sum_{i \in M} \sum_{j \in M} (a_{ij}'' Y_{ij} + b_{ij}'' P_{ij}) + \sum_{j \in M} (c_{sj}'' Y_{sj} + d_{sj}'' P_{sj}) \right], \quad i \neq j \quad (9)$$



Slika 6. Prikaz modela za planiranje SN razdjelne mreže

uz ograničenja:

$$\sum_{j \in M} P_{sj} = S_s \quad \text{za } j \in M \quad (10)$$

$$\sum_{i \in M_u} P_{ij} - \sum_{i \in M} P_{ji} = D_j \quad i \neq j, \quad \text{za } j \in M \quad (11)$$

$$0 \leq P_{ij} \leq P_{\max_{ij}} Y_{ij} \quad i \neq j, \quad \text{za } i, j \in M \quad (12)$$

$$0 \leq P_{sj} \leq P_{\max_{sj}} Y_{sj} \quad \text{za } j \in M \quad (13)$$

$$U_{\min} \leq U_i \leq U_{\max} \quad \text{za } i \in M \quad (14)$$

$$Y_{ij} \in [0,1] \quad i \neq j, \quad \text{za } i, j \in M \quad (15)$$

$$Y_{sj} \in [0,1] \quad \text{za } j \in M \quad (16)$$

gdje su:

- $M = \{1, \dots, m\}$ - skup svih čvorova električne mreže
- s - fiktivni čvor kojem je pridijeljena snaga napajanja jednaka ukupnom opterećenju mreže
- $M_u = M \cup \{s\}$ - skup svih čvorova modela električne mreže
- a''_{ij} - prosječni fiksni troškovi voda od čvora i do čvora j , za $i, j \in M$ [kn]
- b''_{ij} - linearizirani varijabilni troškovi voda po jedinici prenesene radne snage od čvora i do čvora j , za $i, j \in M$ [kn/W]
- P_{ij} - tok radne snage od čvora i do čvora j , za $i, j \in M$ [W]
- $P_{\max ij}$ - maksimalno dozvoljeni tok radne snage od čvora i do čvora j , za $i, j \in M$ [W]
- $U_{\min}$ - minimalni dozvoljeni napon SN mreže [V]
- $U_{\max}$ - maksimalni dozvoljeni napon SN mreže [V]
- c''_{sj} - prošireni prosječni fiksni troškovi transformatorske stanice instalirane u čvoru j , za $j \in M$ [kn]
- d''_{sj} - prošireni linearizirani varijabilni troškovi transformatorske stanice instalirane u čvoru j odnosno varijabilni troškovi pridruženi toku radne snage kroz granu od fiktivnog čvora s do čvora j , za $j \in M$ [kn/W]
- P_{sj} - snaga napajanja transformatorske stanice instalirane u j -tom čvoru električne mreže odnosno tok radne snage od fiktivnog čvora s do čvora j , za $j \in M$ [W]
- $P_{\max sj}$ - maksimalna radna snaga koju može dati transformatorska stanica instalirana u čvoru j električne mreže odnosno najveći dozvoljeni tok radne snage od čvora s do čvora j , za $j \in M$ [W]
- S_s - snaga napajanja u čvoru s [W]
- D_j - snaga potrošnje u čvoru j , za $j \in M$ [W]

$$Y_{ij} = \begin{cases} 1, & \text{ako je } P_{ij} > 0 \\ 0, & \text{ako je } P_{ij} = 0 \end{cases} \quad i \neq j, \quad \text{za } i, j \in M$$

$$Y_{sj} = \begin{cases} 1, & \text{ako je } P_{sj} > 0 \\ 0, & \text{ako je } P_{sj} = 0 \end{cases} \quad \text{za } j \in M.$$

Veličine a''_{ij} i b''_{ij} su definirane izrazima:

$$a''_{ij} = a'_{ij} l_{ij} \quad (17)$$

$$b''_{ij} = b'_{ij} l_{ij} \quad (18)$$

gdje su:

- a'_{ij} - prosječni fiksni troškovi voda po jedinici duljine od čvora i do čvora j , za $i, j \in M$ [kn]
- b'_{ij} - linearizirani varijabilni troškovi voda po jedinici duljine i jedinici prenesene radne snage od čvora i do čvora j , za $i, j \in M$ [kn/W]
- l_{ij} - udaljenost od čvora i do čvora j , za $i, j \in M$ [km].

Troškovi postojećih napojnih transformatorskih stanica (c_{sj}'') i vodova (a_{ij}'') ne uključuju troškove investicija.

Problem opisan relacijama od (9) do (16) predstavlja *problem linearnog mješovito-cjelobrojnog programiranja* koji se često naziva i *problem fiksnih troškova* što u konkretnom slučaju čak i preko imena pokazuje koliko je neka opća struktura matematičkog modela karakteristična za određeni problem. Inače, u konkretnom modelu je napravljena aproksimacija jer je varijabilna komponenta troškova u funkciji cilja (9) linearizirana, a stvarno je kvadratno ovisna o P .

Opisani model je statički što znači da se vrijeme ne uzima eksplicitno u razmatranje. Međutim, njegovom višestrukum primjenom može se obuhvatiti vremenska komponenta odnosno realizirati pseudodinamički pristup. Ovaj pristup se inače i najčešće koristi jer dinamički model bitno povećava dimenzije problema, a i sa stanovišta planiranja predložena rješenja se uobičajeno preispituju nakon realizacije pojedinih etapa radi realnijeg sagledavanja ulaznih podataka npr. prognoze opterećenja.

Pouzdanost nije izravno kao varijabla uključena u optimizacijski proces nego je posredno preko unaprijed definirane strukture mreže zadana kao ograničenje.

Ako se buduća mreža planira kao prostorno radijalna onda se optimizacijskom problemu definiranom relacijama od (9) do (16) dodaje ograničenje:

$$\sum_{i \in M_u} \sum_{j \in M} Y_{ij} = M \quad , \quad i \neq j \quad (19)$$

Ako se zahtijeva da planirana mreža bude prostorno zamkasta odnosno da svaki čvor bude povezan s dvije grane onda se umjesto ograničenja (19) dodaje (20):

$$\sum_{j \in M} Y_{ji} + \sum_{j \in M} Y_{ij} = 2 \quad i \neq j, \quad \text{za } i \in M' \quad (20)$$

gdje je:

M' - skup potrošačkih čvorova električne mreže odnosno čvorova u kojima nisu instalirane napojne transformatorske stanice.

4.4. Uključivanje pouzdanosti u proces planiranja

Matematički model za planiranje srednjenaponskih razdjelnih mreža opisan u točki 4.3 ne obuhvaća pouzdanost kao varijablu u optimizacijskom procesu, nego samo kao ograničenje. Funkcija cilja koja uključuje i pouzdanost kao varijablu može se prikazati izrazom:

$$\min \left[\sum_{i \in M} \sum_{j \in M} (a_{ij}'' Y_{ij} + b_{ij}'' P_{ij}) + \sum_{j \in M} (c_{sj}'' Y_{sj} + d_{sj}'' P_{sj}) + \sum_{k=1}^{ne} \sum_{i=1}^{M'} m_i D_i c_{ik}(r_k) \lambda_k \right] \quad , \quad i \neq j \quad (21)$$

gdje su:

- ne - broj elemenata mreže čiji se kvarovi razmatraju
- m_i - faktor opterećenja čvora i
- $c_{ik}(r_k)$ - jedinični troškovi prekida napajanja čvora i radi kvara elementa k koji traje r_k sati [kn/W]
- r_k - prosječno vrijeme trajanja kvara elementa k [h]
- λ_k - učestalost kvara elementa k mreže [kvar/god].

Ograničenja su ista kao za funkciju cilja prikazanu izrazom (9) odnosno mogu se opisati relacijama od (10) do (16).


4.5. Neki karakteristični modeli planiranja

Matematički modeli za optimalno planiranje srednjenaponskih elektroenergetskih razdjelnih mreža u principu predstavljaju probleme mješovito-cjelobrojnog nelinearnog programiranja. Problem opisan relacijama od (9) do (16) predstavlja problem linearnog mješovito-cjelobrojnog programiranja jer su kvadratni varijabilni troškovi linearizirani. Navedeni modeli osim kontinuiranih sadržavaju i cjelobrojne tj. diskretne varijable te spadaju u klasu kombinatoričkih problema a koji su sa stanovišta rješavanja vrlo složeni (tzv. **NP**-teški problemi) [29].

Razmotreno je nekoliko specifičnih varijanti modela za planiranje razdjelnih mreža.

4.5.1. Model s lineariziranim fiksnim troškovima

Radi jednostavnosti, promatra se samo dio funkcije cilja (9) koji uključuje troškove SN vodova. Linearizacija ukupnih troškova voda prikazana je na slici 7.



Slika 7. Linearizacija fiksnih troškova voda

Sada se odgovarajuća funkcija cilja može napisati kao:

$$\min \sum_{i \in M} \sum_{j \in M} \left(\frac{a''}{P_{ij \max}} + b_{ij}'' \right) P_{ij} \quad , \quad i \neq j \quad (22)$$


a problem se svodi na linearni odnosno *pretovarni (transshipment)*, koji je lako rješiv.

Dobiveno rješenje (s lineariziranim fiksnim troškovima) predstavlja donju granicu na stvarno rješenje (u kojem fiksni troškovi nisu linearizirani). Ako se u optimalnom rješenju problema (22) svim vodovima koji imaju $P > 0$ pridijele realni umjesto aproksimativnih fiksnih troškova dobiva se gornja granica vrijednosti stvarnog rješenja.

4.5.2. Modeli s fiksnim troškovima vodova

Obrađeni su slučajevi kada su lokacije i snage napojnih transformatorskih stanica poznate unaprijed, a traži se samo optimalna konfiguracija SN vodova. Prepostavljeno je da su vodovi opisani jedino fiksnim troškovima.

U slučaju prostorno radijalnih mreža (pokrajinske mreže) problem se svodi na određivanje *najkraćeg stabla* (*minimum spanning tree*), slika 8. Problem je lako rješiv, a neki od potencijalnih algoritama su: *Kruskal*-ov, *Prim*-ov i dr.



Slika 8. Prostorno radijalna mreža
(problem određivanja minimalnog stabla)


Gradske razdjelne mreže se izvode kao prostorno zamkaste. Tipične strukture su prstenasta i povezna. Na slici 9. je prikazana gradska mreža s 1 prstenom. Određivanje optimalne konfiguracije takve mreže predstavlja *problem trgovačkog putnika* (*traveling salesman problem*).

Problem je prvi put postavio K. Menger 1930. godine. Izvorno je nazvan *problem glasnika* (njem. *Botenproblem*), a kasnije je dobio sadašnji naziv [27].

Problem trgovačkog putnika se može definirati kao traženje najkraćeg puta obilaska svih gradova (TS SN/NN), uz uvjet da trgovački putnik može neki grad posjetiti samo jedanput, osim prvoga (napojna TS) iz kojeg polazi i u koji se mora vratiti.


Na slici 9. nisu prikazane sve moguće veze između čvorova. U slučaju da je potencijalno ostvariva veza između svih m čvorova mreže (1 napojna TS, $m-1$ TS SN/NN), broj mogućih kombinacija iznosi $0.5 \cdot (m-1)!$ ili $6.4023737 \cdot 10^{15}$ za konkretnu mrežu ($m=19$). Za razliku od određivanja minimalnog stabla, problem trgovačkog putnika spada u složene probleme.

Na slici 10. je prikazana gradska mreža s 1 napojnom trafostanicom i 2 prstena. Ovaj problem predstavlja problem *višestrukog trgovačkog putnika* (*multiple traveling salesman problem*). Međutim, zbog ograničenog kapaciteta izvoda preciznije ga je definirati kao *problem dostave* (*capacitated vehicle routing problem*, *vehicle dispatch problem*) ili u konkretnom slučaju jer se radi o jednoj napornoj trafostanici kao *problem dostave iz jednog skladišta* (*single-depot capacitated vehicle routing problem*) [4,23].




Slika 9. Prstenasta mreža - 1 prsten
(problem trgovačkog putnika)

Problem dostave iz jednog skladišta (napojna TS) se definira kao određivanje ukupnog minimalnog puta (mreže) koji će prijeći n vozila (izvoda) ograničenog kapaciteta da bi posjetili i opskrbili sve potrošače (TS SN/NN) samo jedanput i vratili se na mjesto polaska (napojna TS).



Slika 10. Prstenasta mreža – više prstenova
(problem dostave iz jednog skladišta)

Na slici 11. je prikazan primjer gradske povezne mreže. Određivanje optimalne mreže predstavlja *problem dostave iz više skladišta (multi-depot capacitated vehicle routing problem)*.



Slika 11. Povezna mreža
(problem dostave iz više skladišta)

4.5.3. Model opskrbnog područja napojne trafostanice

Prikazan je primjer određivanja opskrbnog područja napojne trafostanice [8]. Primjer s dvije napojne trafostanice predočen je na slici 12.


Najprije se između svake napojne trafostanice i svake TS SN/NN odredi minimalna udaljenost l_{ij} primjenom nekog od algoritama za određivanje najkraćeg puta između dva čvora (npr. *Dijkstra*-in algoritam). Zatim se problem određivanja opskrbnih područja napojnih transformatorskih stanica definira kao *transportni problem (transportation problem)*:

$$\min \sum_{i=1}^{M_S} \sum_{j=1}^{M_D} l_{ij} P_{ij} \quad (23)$$

uz ograničenja:

$$\sum_{j=1}^{M_D} P_{ij} = S_i \quad i=1, \dots, M_S \quad (24)$$

$$\sum_{i=1}^{M_S} P_{ij} = D_j \quad j=1, \dots, M_D \quad (25)$$



Slika 12. Optimalna područja opskrbe napojnih trafostanica

gdje su:

- S_i - snaga napojne trafostanice i [W]
- M_S - broj napojnih trafostanica
- M_D - broj TS SN/NN.

Transportni problem je linearan, što znači relativno lagano rješiv.

4.6. Problem donošenja odluke

Planer često mora donositi odluke o izgradnji uvažavajući neodređenost odnosno realnu mogućnost pojave različitih uvjeta koji bitno utječu na razvoj mreže. To se prije svega odnosi na utjecaj mjesta pojave i veličine opterećenja, a različitim scenarijima porasta opterećenja odgovaraju i drugačije optimalne konfiguracije mreže.

Opisana su dva kriterija uvažavanja neodređenosti. Jedan je *kriterij očekivanih troškova* (*expected cost criterion*) koji se zasniva na *vjerojatnosnom principu*, a drugi je *kriterij maksimalne štete* (*maximum regret criterion*) koji se bazira na *analizi rizika* [28,31].

Primjena vjerojatnosnog principa se zasniva na pretpostavci da su zakonitosti prema kojima se ponašaju uvjeti za ponavljanje eksperimenata, čiji rezultati su slučajne prirode, nepromjenjive. Osim toga pretpostavlja se da postoji značajan, signifikantan broj eksperimenata tako da frekvencija bilo koje pojave teži vjerojatnosti koja joj je pridijeljena.

Neka postoji više scenarija rasta opterećenja, od kojih neki scenarij k ima vjerojatnost pojave w_k . Ako funkcija f_{ik} označava troškove mreže u slučaju da se mreža gradi po rješenju i uz scenarij porasta konzuma k , onda se najpovoljnije rješenje i određuje kao:

$$\min_i \sum_k w_k f_{ik} \quad (26)$$

Pri tome je neko rješenje i optimalno samo za jedan određen rast konzuma.

Analizom rizika traži se ono rješenje koje minimizira štetu u slučaju da se ne ostvari predviđeni scenarij rasta konzuma nego neki drugi. Šteta koju planer valorizira u slučaju rasta konzuma po nekom scenariju se najčešće iskazuje kao maksimalna razlika između troškova dobivenih primjenom rješenja mreže koje ima najveće troškove i rješenja koje ima optimalne troškove za dani scenarij. Ako je f_k^{op} optimalno rješenje za neki scenarij, onda je po kriteriju maksimalne štete najpovoljnije rješenje i :

$$\min_i \left\{ \max_k \left[w_k (f_{ik} - f_k^{op}) \right] \right\} \quad (27)$$

Vjerojatnosni princip je konzistentan uvijek kada planer donosi odluku znajući da se događaji ponavljaju. Tada može biti statistički siguran da će se neki loš događaj kompenzirati nekim dobrim. Analizom rizika uzimaju se u obzir vrlo loši događaji. Kod planiranja mreže je upitno može li se neka loša odluka npr. o gradnji napojne transformatorske stanice kompenzirati odlukom o gradnji neke druge. Zato se čini primjerenijim pristup analize rizika [28].

Donošenje odluke planera ilustrirano je na jednom jednostavnom primjeru.

Neka postoje 3 scenarija porasta konzuma S1, S2 i S3 i za svaki od tih scenarija odgovarajuća optimalna rješenja R1, R2 i R3. Scenariji S1, S2 i S3 imaju vjerojatnosti realizacije $w_1=0.35$, $w_2=0.4$ i $w_3=0.25$, a vrijednosti optimalnih rješenja za svaki scenarij su R1=1000, R2=1450 i R3=1650.

U tablici II. su prikazani ukupni troškovi pojedine varijante rješenja za svaki scenarij porasta konzuma. Također su prikazani i očekivani troškovi svakog rješenja. Podebljano otisnuti brojevi se odnose na optimalne vrijednosti za svaki scenarij kao i na očekivane troškove rješenja koje je najbolje prema navedenom kriteriju.

Tablica II. Troškovi pojedinih rješenja za različite scenarije i očekivani troškovi pojedinih rješenja

	S1	S2	S3	Oč. troškovi
R1	1000	1500	2200	1500
R2	1100	1450	2300	1540
R3	1300	1600	1650	1507.5

U tablici III. su iskazane štete koje bi se javile zbog realizacije nekog rješenja a u okviru porasta opterećenja po nekom od scenarija. Deblje su otisnuti iznosi najvećih šteta koje se javljaju u okviru nekog scenarija kao i konačno vrijednost štete koja se odnosi na ono rješenje čija realizacija izaziva najmanju maksimalnu štetu s obzirom na sve scenarije.


Tablica III. Štete radi realizacije pojedinih rješenja s obzirom na različite scenarije porasta opterećenja

	S1	S2	S3	Maks. šteta
R1	0	20	137.5	137.5
R2	35	0	162.5	162.5
R3	105	60	0	105

Uočava se da je prema kriteriju očekivanih troškova najbolje rješenje R1, a prema kriteriju maksimalne štete najpovoljnije rješenje je R3.

Iako je napomenuto da je za planiranje razdjelnih mreža prihvatljiviji kriterij maksimalne štete, ipak je u ovakvim slučajevima dobro dodatno istražiti utjecaj raspona vrijednosti težinskih vjerojatnosti w_1 , w_2 i w_3 koje se odnose na pojavu pojedinih scenarija. S obzirom da se radi o 3 veličine i da vrijedi $w_1+w_2+w_3=1$ utjecaj promjene vjerojatnosti pojave pojedinih scenarija se može prikazati u (w_1, w_2) ravni.

Na slici 13. je kvalitativno prikazano područje stabilnosti pojedinog rješenja uz variranje vrijednosti vjerojatnosti pojave pojedinog scenarija. U najvećem rasponu vrijednosti težina rješenje R3 je najbolje prema oba kriterija.



Slika 13. Kvalitativni prikaz područja stabilnosti rješenja

5. OPTIMIZACIJSKE METODE ZA RJEŠAVANJE PROBLEMA PLANIRANJA

5.1. Tipovi metoda

Općenito, matematički modeli za optimalno planiranje srednjenaponskih razdjelnih mreža se razlikuju po tome u kojem opsegu obuhvaćaju njene bitne elemente i s kojim stupnjem detalja ih opisuju. Što je veći broj razmatranih elemenata i značajki planiranja (napojne transformatorske stanice, SN vodovi, pouzdanost, uvažavanje vremenske komponente itd.) i što su one detaljnije prezentirane (fiksni troškovi, varijabilni troškovi, troškovi neisporučene električne energije, dinamički pristup i sl.) modeli su složeniji i samim time računski zahtjevniji.

Bez obzira na strukturu modela, primijenjena metoda rješavanja može biti točna ili aproksimativna. Ako se optimizacijski model svodi na problem traženja najkraćeg stabla, transportni problem, pretovarni problem i sl., onda se točnim metodama mogu u prihvatljivom vremenu izvođenja (polinomnom) riješiti problemi realnih dimenzija. Ako se radi o modelima mreže koji imaju strukturu problema fiksnih troškova, problema dostave i sl. odnosno koji su po svojoj prirodi kombinatorički, primjena točnih metoda je ograničena na probleme malih dimenzija. U takvim slučajevima se koriste aproksimativne metode.

Primjena kompjutera i optimizacijskih metoda u planiranju razdjelnih mreža započinje 60-tih godina prošlog stoljeća i od tada se stalno intenzivira [17,21]. Interesantno je napomenuti da su u ranijem razdoblju (70-tih i 80-tih godina) za rješavanje problema planiranja prevladavale metode matematičkog programiranja tj. točne metode, a kasnije heurističke odnosno aproksimativne metode.

Za potrebe optimalnog planiranja srednjenaponskih razdjelnih mreža razvijeno je mnoštvo matematičkih modela i metoda rješavanja. O tome postoji iscrpna literatura, a na koju između ostalog ukazuju i vrlo dobri pregledni članci [16,19,40,41]

5.2. Točne metode

Ovisno o strukturi funkcije cilja i ograničenja, neki optimizacijski problem se svrstava u različite klase (linearno programiranje, cjelobrojno programiranje, linearno mješovito-cjelobrojno programiranje, kvadratno programiranje, nelinearno programiranje, dinamičko programiranje itd.).

Npr. problem opisan relacijama (9)-(16) spada u klasu mješovito-cjelobrojnih linearnih problema odnosno, šire, kombinatoričkih problema, a oni su sa stanovišta rješavanja složeni.

Metode kojima se mješovito-cjelobrojno linearni problemi rješavaju mogu se prema osnovnim idejama podijeliti na:

- metode odsijecajućih ravnina
- metode prebrojavanja i enumeracije
- metode razdvajanja.

Metode prebrojavanja se dijele na *metode grana i granica* i na *metode pretraživanja*.


Na jednostavnom primjeru, i to samo načelno, ilustrirana je jedna metoda za rješavanje linearnih problema. Radi se o *simpleks metodi*, vjerojatno najpoznatijoj metodi matematičkog programiranja. Osnovnu verziju metode je osmislio G. Dantzig 1947. godine i objavio 4 godine poslije [27].

Radi lakše predodžbe odabran je problem s dvije varijable. Funkcija cilja z koju treba maksimizirati prikazana je izrazom (28), a mora zadovoljavati ograničenja opisana relacijama (29).

$$\max z = \max (-2x_1 + x_2) \quad (28)$$

$$\begin{aligned} -x_1 + x_2 &\leq 3 \\ 2x_1 + x_2 &\leq 13 \\ x_1 &\leq 5 \\ x_2 &\leq 5 \\ x_1, x_2 &\geq 0 \end{aligned} \quad (29)$$

Geometrijska interpretacija funkcije cilja i ograničenja prikazana je na slici 14.



Slika 14. Geometrijski prikaz funkcije cilja i ograničenja

Ograničenja (29) omeđuju područje prihvatljivih rješenja i ono je na slici 14. prikazano kao poligon sa zadebljanim linijama. Rješenja izvan poligona su neprihvatljiva. U slučaju s 3 varijable područje odnosno prostor rješenja bi predstavljao tetraedar, a u slučaju s n varijabli to bi bio n -dimenzionalni poliedar.

Pravac koji je parametarski zadan vrijednošću funkcije cilja na slici je predočen zadebljano crtkano. S obzirom na činjenicu da je prostor prihvatljivih rješenja konveksan skup (*geometrijski*: neki skup je konveksan ako se bilo koje dvije točke toga skupa mogu povezati spojnicom koja je i sama dio tog skupa) onda je očito da upravo u vrhovima poligona treba tražiti optimalna prihvatljiva rješenja. U konkretnom slučaju translirajući pravac preko područja rješenja dolazi se do vrha (0,3) u kojem funkcija cilja ima maksimalnu vrijednost $z^*=3$.

Činjenicu da se optimalno rješenje nalazi u vrhovima n -dimenzionalnog poliedra iskorištava simpleks metoda. Naime, ona je zasnovana na inteligentnom pretraživanju susjednih vrhova poliedra. Kada se jedanput nađe u nekom vrhu, onda ide prema susjednom koji najviše povećava vrijednost funkcije cilja. Ako više nema susjednih vrhova u kojima bi se moglo ostvariti poboljšanje vrijednosti funkcije cilja, znači da je nađeno optimalno rješenje i proces pretraživanja završava.

Npr. neka je trenutno prihvatljivo rješenje definirano vrhom, točkom (4,5), tj. $x_1=4$, $x_2=5$ i $z=-3$. Iz vrha (4,5) može se ići u susjedne vrhove (2,5) i (5,3). S obzirom da simpleks algoritam usmjerava promjene prema vrhu koji najviše povećava vrijednost funkcije cilja, očito je da se ide prema vrhu (2,5), jer rješenje u vrhu (5,3) predstavlja smanjenje vrijednosti funkcije cilja. Iz vrha (2,5) se može ići prema vrhovima (0,3) ili vratiti ponovo u vrh (4,5). Povratak na prethodni vrh znači ponovno smanjenje trenutne vrijednosti funkcije cilja pa po definiciji otpada. Ostaje mogućnost kretanja prema vrhu (0,3) i ona se prihvaća jer povećava vrijednost funkcije cilja. Tu proces završava jer više ne postoje susjedni vrhovi u kojima bi se vrijednost funkcije cilja poboljšala.

Inače, sama simpleks metoda, iako vrlo praktična, ne predstavlja algoritam čije se operacije teorijski izvršavaju u polinomno ograničenom vremenu. Kao primjer metode za rješavanje linearnih problema, čije je vrijeme izvršenja polinomno ograničeno, može se navesti *metoda unutarnje točke* (*interior point method*) ili *Karmarkar-ov* algoritam.

5.3. Aproksimativne metode

Modeli za planiranje razdjelnih mreža koji uključuju fiksne i varijabilne troškove ili samo fiksne ali se traži unaprijed zadana prstenasta ili povezna struktura mreže predstavljaju složene probleme sa stanovišta rješavanja. Dakle, ako se ne provedu zanemarenja, a koja mogu drastično narušiti vjerodostojnost modela, problemi planiranja su najčešće računski složeni. U takvim uvjetima primjena točnih metoda zbog zahtijevanog vremena izvođenja je ograničena na probleme manjih dimenzija. Zato se koriste aproksimativne metode.

Aproksimativne metode, za razliku od točnih, ne garantiraju pronalaženje globalnog optimuma.

Podjela između točnih i aproksimativnih metoda ne mora biti striktna. Npr. uvođenjem određenih spoznajnih pravila u metodu grana i granica ona iz točne prelazi u klasu aproksimativnih algoritama.


Aproksimativni algoritmi se često zovu i *heuristički*. Naziv dolazi od grčke riječi *heuriskein* (*pronaići, otkriti*). Kada se počeo upotrebljavati, termin heuristički primjenjivao se u drugačijem kontekstu nego što je danas, npr. označavao je metode koje dovode do globalnog optimuma, pa je i etimologija riječi bila primjerena [37]. S obzirom na to što se danas podrazumijeva pod nazivom heuristički bio bi prikladniji korijen riječi *tražiti*.

Općenito, heuristički postupak je znanstveno istraživanje koje koristi nedokazane tvrdnje i iskustvena pravila. Sa stanovišta metoda za rješavanje optimizacijskih problema, heuristički postupak je algoritam koji traži dobra (blizu optimalna) rješenja u prihvatljivom vremenu i pri tome ne može garantirati ni prihvatljivost niti optimalnost, a u nekim slučajevima niti procjenu koliko je neko postignuto rješenje lošije od stvarno optimalnog [37].


Nekad se složenije heurističke metode zovu i *metaheurističke* kako bi se naglasila razlika između jednostavnijih heurističkih postupaka orijentiranih pronalaženju prvog, najčešće lokalnog, optimuma [14].

Aproksimativni ili heuristički algoritmi se mogu podijeliti na dvije skupine, *općenite* i *problemu orijentirane* postupke [1]. Općeniti algoritmi su primjenjivi na široki broj problema i neovisni su o njihovoj strukturi, dok se problemu orijentirani algoritmi zasnivaju na specifičnim informacijama o problemu i imaju ograničenu primjenu.

Na slici 15. je kvalitativno prikazana vrijednost funkcije $f(\mathbf{x})$, za $\mathbf{x} \in \mathbf{X}$, gdje je $\mathbf{X}$ skup prihvatljivih rješenja tj. onih koja zadovoljavaju zadana ograničenja. Uz pretpostavku da se traži minimum, točke A, B, C, D, E i F predstavljaju optimume funkcije cilja. Točka D je globalni, a ostale su lokalni optimumi.

Slika 15. Globalni i lokalni optimumi funkcije $f(x)$

Kao primjer jednostavnije heurističke metode, dakle one koja ne spada u metaheurističke, navest će se *metoda izmjene grana (branch exchange method)*. Metoda je ilustrirana na mreži prikazanoj na slici 16.



Slika 16. Metoda izmjene grana

Na slici 16. je prikazano jedno trenutno rješenje prostorno radijalne razdjelne mreže u procesu optimiranja. Postoje razni kriteriji za zamjenu grana. Neka je ovdje primijenjeno sukcesivno ispitivanje grana koje ne čine stablo rješenja. Faza izmjene grana započinje odabirom grane koja nije dio trenutnog rješenja, a još nije ispitana (npr. grana g). Njenim ulaskom stvara se petlja koju osim nje čine grane a , b , c , d , e , i f tekućeg rješenja. Iz petlje potom izlazi ona grana čijim izlaskom se ne narušavaju ograničenja i ostvaruje najveće poboljšanje funkcije cilja. Zatim se faza izmjene grana ponavlja sve dok neka grana koja nije dio rješenja svojim ulaskom može poboljšati vrijednost funkcije cilja. Inače se proces zaustavlja i postiže se lokalni optimum, koji slučajno može biti i globalni. Npr. ako je prema slici 15 procedura izmjene grana započela iz nekog početnog rješenja P završit će u lokalnom optimumu C .

Metaheuristički ili složeniji heuristički algoritmi imaju razrađene mehanizme kako proces pretraživanja "izbaciti" iz lokalnog optimuma u dotad neistraženi dio prostora rješenja.

Dobre metaheurističke metode karakteriziraju jednostavnost, preciznost, dosljednost, djelotvornost, robustnost i inovativnost [14].

U osnovnim crtama opisane su tri heurističke metode.

5.3.1. Stohastička relaksacija (simulated annealing)

Stohastička relaksacija (simulirano hlađenje, simulirano napuštanje) je metaheuristička metoda zasnovana na ideji iz algoritma kojim se simulira hlađenje rastaljenog krutog tijela (N. Metropolis i dr., 1953. g.) [1,9,37].

Da bi se razumjela veza između tehnika u statističkoj termodinamici i rješavanja optimizacijskih problema, treba poznavati osnove statističke termodinamike. Statistička termodinamika opisuje ponašanje međudjelovanja vrlo velikih sustava komponenata, kao što su atomi u fluidu, u termičkoj ravnoteži pri konačnoj temperaturi. Neka je konfiguracija odnosno stanje sustava određeno skupom prostornih pozicija komponenata. Ako je sustav u termičkoj ravnoteži pri zadanoj temperaturi T , onda vjerojatnost $P_T(i)$ da je sustav u stanju i ovisi o energiji $E(i)$ stanja i ravna se po Boltzmann-ovoj distribuciji:

$$P_T(i) = \frac{e^{-\frac{E(i)}{k_B T}}}{\sum_{j \in ST} e^{-\frac{E(j)}{k_B T}}} \quad (30)$$

gdje je k_B Boltzmann-ova konstanta, a ST skup svih mogućih stanja.

Ponašanje sustava čestica, atoma u termičkoj ravnoteži pri temperaturi T može se opisati tehnikom *stohastičke relaksacije* koju su razvili Metropolis i suradnici. Neka je u trenutku t sustav u stanju i . Kandidat za stanje j u trenutku $t+1$ se generira slučajno. Kriterij odabira ili odbacivanja stanja j ovisi o razlici energija između stanja j i i . Određenje, računa se omjer p između vjerojatnosti stanja j i vjerojatnosti stanja i :

$$p = \frac{P_T(j)}{P_T(i)} = e^{-\frac{E(j)-E(i)}{k_B T}} \quad (31)$$

Ako je $p > 1$ odnosno ako je energija stanja j manja od energije stanja i , stanje j se automatski prihvaća kao novo stanje u trenutku $t+1$. Ako je $p \leq 1$ odnosno energija stanja j veća ili jednaka od energije stanja i , stanje j se prihvaća kao novo s vjerojatnošću p . Dakle, moguće je postići stanje s većom energijom. Može se pokazati da je vjerojatnost da je sustav u stanju s , za $t \rightarrow \infty$, jednaka $P_T(s)$, bez obzira na početno stanje, i da se raspodjela ponaša po Boltzmann-ovoj distribuciji [9].

U razmatranju ovakvih sustava čestica često se traži određivanje prirode stanja s malim energijama, npr. stvaraju li se hlađenjem kristalne strukture. Stanja s malim energijama nisu uobičajena, osobito s aspekta ukupnog broja stanja. Međutim, na malim temperaturama ona dominiraju radi osobina Boltzmann-ove distribucije. Da se postignu stanja s malim energijama nije dovoljno samo smanjiti temperaturu, nego treba provesti i proces ohlađivanja ili popuštanja (*annealing*) pri čemu se temperatura najprije poveća iznad točke taljenja, a zatim postupno smanjuje, zadržavajući se dovoljno vremena na svakom iznosu temperature T da se postigne termička ravnoteža. Treba naglasiti da je vjerojatnost postizanja stanja s vrlo malim energijama jako reducirana, ako se ne provede dovoljno vremena na svakoj temperaturi, posebno u blizini točke skrućivanja.

Kirkpatrick sa suradnicima i Černý su 1983. godine neovisno pokazali kako se Metropolis-ov algoritam može primijeniti na probleme kombinatoričke optimizacije [1,9,20,37]. U tablici IV. je prikazana veza između termodinamičke simulacije i optimizacijskog procesa.

Tablica IV. Veze termodinamičke simulacije i optimizacije

Termodinamička simulacija	Kombinatorička optimizacija
Stanja sustava	Prihvatljiva rješenja
Energija	Troškovi
Promjena stanja	Susjedno rješenje
Temperatura	Kontrolni parametar
Kruto stanje	Optimalno rješenje

Rješenja optimizacijskog problema odgovaraju stanjima fizikalnog sustava, a funkcija cilja energiji stanja. U svakom koraku (iteracija k , temperatura T_k) algoritma dopušta se određeni broj pomaka m_k iz trenutnog, aktualnog rješenja u njemu susjedno rješenje. Proizvoljni pomak iz trenutnog rješenja ostvaruje se promjenom jedne ili više varijabli pri čemu se računa rezultirajuća promjena funkcije cilja Δz_k . Pomakom se postiže novo rješenje i ako je $\Delta z_k \leq 0$ (kretanje nizbrdo) taj se pomak prihvaća i usvaja novo rješenje kao početno za novi pomak. Slučaj $\Delta z_k > 0$ (kretanje uzbrdo) se razmatra preko vjerojatnosti prihvatanja pomaka tj. vjerojatnosti prihvatanja promjene vrijednosti funkcije cilja $P(\Delta z_k) = \exp(-\Delta z_k/c_k)$ gdje je c_k kontrolni parametar. U ovom slučaju generira se proizvoljni broj uniformno distribuiran u intervalu $[0,1]$ i uspoređuje s vrijednošću $P(\Delta z_k)$. Ako je proizvoljni broj iz intervala $[0,1]$ manji ili jednak od $P(\Delta z_k)$ onda se novo rješenje prihvaća kao početno za budući pomak. U suprotnom se kretanje uzbrdo odbacuje i ostaje na prethodnom rješenju. Kada se iscrpi definiran broj pomaka m_k , prelazi se na slijedeću iteraciju $k+1$. Postupak završava kada ne postoji značajnija promjena funkcije cilja u danom broju uzastopnih iteracija. Uvjet kojim se osigurava asimptotska konvergencija prema globalnom optimumu je $c_k = 0$ za $k \rightarrow \infty$ i $c_{k+1} \leq c_k$ za $k=0,1,\dots$. Parametri čije podešenje utječe na tok optimiranja su početna vrijednost kontrolnog parametra c_0 , promjena kontrolnog parametra $c_{k+1} = f(c_k)$, krajnja vrijednost kontrolnog parametra c_s (kriterij završetka postupka) te broj dopustivih pomaka za danu iteraciju m_k .

Algoritam stohastičke relaksacije se može opisati u 7 koraka:

- Korak 1:** Odredi kontrolni parametar c_0 ,
odredi početni broj pomaka m_0 ,
odaberi početno rješenje $\mathbf{x}_0 \in \mathbf{X}$;
- Korak 2:** $k=0$, $\mathbf{x} := \mathbf{x}_0$;
- Korak 3:** Ako su ispunjeni kriteriji za završetak, onda je KRAJ,
 $k_m=0$;
- Korak 4:** Odredi $\mathbf{x}' \in \mathbf{N}(\mathbf{x})$;
- Korak 5:** Ako je $z(\mathbf{x}') \leq z(\mathbf{x})$ ili $\exp((z(\mathbf{x}) - z(\mathbf{x}'))/c_k) > \text{random}[0,1]$
onda je $\mathbf{x} := \mathbf{x}'$;
- Korak 6:** $k_m := k_m + 1$,
ako je $k_m < m_k$ idi na 4;
- Korak 7:** Izračunaj $m_{k+1} = f(m_k)$,
izračunaj $c_{k+1} = f(c_k)$,
 $k := k + 1$,
Idi na 3.

Broj iteracije je označen s k , a skup $\mathbf{N}(\mathbf{x})$ označava skup svih prihvatljivih rješenja u susjedstvu rješenja $\mathbf{x}$. Svako rješenje u $\mathbf{N}(\mathbf{x})$ može se dobiti pomakom iz $\mathbf{x}$.

Ako bi se metoda stohastičke relaksacije primijenila na mrežu prikazanu na sl. 16, to bi značilo da se izmjena nekih grana, koja ne dovodi do poboljšanja vrijednosti funkcije cilja, ipak dopušta s određenom vjerojatnošću. Takvi mehanizmi omogućuju izlazak iz lokalnih optimuma i usmjeravaju pretraživanje u neistražena područja prostora rješenja.

5.3.2. Genetski algoritam

Genetski algoritam spada u skupinu evolucijskih algoritama zasnovanih na analogiji s principima evolucije kao svojevrsnog prirodnog optimizacijskog procesa kojim se živi organizmi prilagođuju promjenama okoline. Teorija evolucije koju je postavio Darwin objašnjava promjene vrsta prema principu *prirodnog odabiranja* po kojem se za preživljavanje i daljnju evoluciju favoriziraju vrste najbolje prilagođene uvjetima okoline. Moderna biokemija i genetika su proširili Darwinovu teoriju mikroskopskim otkrićima mehanizama nasljeđivanja. Rezultirajuća teorija se zove sintetička teorija evolucije ili neodarvinizam. Zasniva se na *genima* odnosno *kromosomima* kao nositeljima nasljeđivanja [2].

“Znanje” koje je svaka vrsta stekla uključeno je u strukturu kromosoma njenih jedinki. Najvažnije operacije koje pri reprodukciji roditelja mijenjaju strukturu kromosoma su *mutacija* i *križanje* ili *rekombinacija*. Mogla bi se navesti i inverzija kojom se mijenja *lokacija* (*locus*) gena u kromosomu i omogućuje grupiranje gena povećavajući njihovu vjerojatnost zajedničkog prenošenja prilikom križanja. Mutacija predstavlja slučajnu promjenu vrijednosti ili osobine gena. Vrijednost, osobina ili stanje gena na zove se *alel* (*allele*). Križanje je ključni mehanizam i znači izmjenu odgovarajućeg genetskog materijala između kromosoma dvaju roditelja dopuštajući korisnim genima da se združuju u njihovim potomcima.

Simuliranje evolucije ima dugu povijest, a slične ideje i primjene nezavisno su se javljale mnogo puta (Cannon 1932., Turing 1950., Friedman 1959. itd.) [3,10]. Rani pokušaji automatskog programiranja i optimiranja jednostavnih funkcija općenito su bili neuspješni radi neodgovarajuće implementacije i izostavljanja fundamentalnih aspekata prirodne evolucije. Ovi aspekti su uključivanje populacija s različitim rješenjima i, u manjoj mjeri, stohastička selekcija.

Tri glavna pravca istraživanja rezultirala su pojavom tri tipa *evolucijskih algoritama* [10]:

- a) genetski algoritmi (Holland 1969., 1975.)
- b) evolucijske strategije (Rechenberg 1965., Schwefel 1965.)
- c) evolucijsko programiranje (L. Fogel 1962.).

Svaki sadržava populaciju trenutnih (pokusnih) rješenja, vrši slučajne promjene ovih rješenja i uključuje selekciju radi određivanja koja rješenja zadržati u budućim generacijama a koja ne. Međutim, posjeduju i važne razlike. Genetski algoritam naglašava modele genetskih operatora kakvi se susreću u prirodi (križanje, inverzija i mutacija) i primjenjuje ih na apstraktne kromosome. Evolucijske strategije i evolucijsko programiranje ističu mutacijske transformacije koje zadržavaju vezu ponašanja između svakog roditelja i njegovih potomaka. Rekombinacija odnosno križanje može biti odgovarajuće primijenjeno na jedinke, ali ne i na vrstu. Određene razlike između evolucijskog programiranja i evolucijskih strategija postoje u fazi mutacije i natjecanja.

Genetski algoritam je razvio 1970-tih J. Holland sa Sveučilišta Michigan. Naziv genetski proizlazi iz analogije između prikaza kompleksnih vektorskih struktura i genetske strukture kromosoma. Kao što se razmjenom genetskog materijala roditelja traži potomstvo željenih osobina, tako se u pronalaženju boljih rješenja složenih optimizacijskih problema kombiniraju dijelovi postojećih rješenja.


Pored mutacije, križanja, lokacije, alela i kromosoma kao niza gena, treba definirati još neke pojmove za razumijevanje genetskog algoritma. *Genom* (*genome*) je skup svih gena, ili ukupna količina deoksiribonukleinske kiseline (DNA) u stanici [39]. Sličan naziv *genotip* (*genotype*) označava sveukupni potencijal izražavanja gena tj. plan izgradnje organizma [2]. Genotip se definira kao potencijal izražavanja zato jer se nikada potpuno ne ostvaruje. U pojedinim vrstama stanica i cijelom organizmu izražen je samo dio genotipa koji određuje njihove opće i specifične osobine i taj dio se zove *fenotip* (*phenotype*) [39].

Tablica V. pokazuje usporedbu između terminologije u genetici i optimizaciji.

Tablica V. Veza između nazivlja u genetici i optimizaciji

Genetika	Kombinatorička optimizacija
Gen	Karakter
Lokacija	Položaj karaktera
Alel	Vrijednost karaktera
Kromosom	Niz
Genotip (jedinka)	Struktura (kodirano rješenje)
Fenotip	Dekodirano rješenje
Populacija	Skup rješenja
Generacija	Skup rješenja u nekoj fazi procesa


Na slici 17. prikazana je jedna jedinka (genotip) u populaciji odnosno rješenje u skupu rješenja. U konkretnom slučaju pretpostavljeno je da genotip ima 1 kromosom odnosno niz. Kod je binarni. Fenotip odnosno dekodirano rješenje iznosi 93. Svako rješenje se vrednuje *funkcijom prikladnosti (fitness function)* koja najčešće predstavlja funkciju cilja. U ovom slučaju odabrana je proizvoljna funkcija prikladnosti $f(x)=2x-10$.



Slika 17. Prikaz jednog rješenja

Genotip se može sastojati od više kromosoma (*multiple chromosome structures*), a i kodiranje ne mora biti binarno [15].

Na slici 18. prikazana je ista mreža kao na slici 10., ali s numeriranim granama i čvorovima. Mogućnosti kodiranja rješenja mogu biti vrlo različite. Neka se genotip sastoji od 2 kromosoma koji opisuju dva prstena srednjenaponske razdjelne mreže. Radi ilustracije, prikazana su dva načina opisa prstenova. Jedan koristi oznake grana i binarni kod, a drugi oznake čvorova i dekadski kod.




Slika 18. Mreža s označenim granama i čvorovima

U slučaju binarnog kodiranja, uz pretpostavku da kromosom ima duljinu 31 (ukupan broj potencijalnih grana), da lokacija gena odgovara broju grane i alel 1 da je upotrijebljena, kromosom koji opisuje gornji prsten bi se sastojao od niza 11001 00000 11010 10000 01010 00110 0. U slučaju korištenja oznaka čvorova, niz grana prstena (1,2), (2,6), (6,7), (7,8), (8,14), (14,15), (15,19), (19,16), (16,9), (9,3) i (3,1) se može dekadski prikazati kromosomom 1 2 6 7 8 14 15 19 16 9 3. Zadnji čvor prstena odnosno čvor 1 je ujedno i prvi pa nije prikazan. Dobiveni genotipovi bi se dekodirali u odgovarajuća rješenja za koja bi se izračunale funkcije prikladnosti odnosno funkcije cilja sastavljene od fiksnih i varijabilnih troškova. Iz ovog jednostavnog primjera se vidi koliko je važno za određeni problem odabrati primjereno kodiranje. U tom smislu faza križanja je posebno osjetljiva.

Na slici 19. predložen je prijelaz generacije T u generaciju $T+1$, odnosno dobivanje skupa rješenja u koraku $T+1$ algoritma iz skupa rješenja u koraku T . Iz generacije T koja čini jednu populaciju od n jedinki (genotipova) se prema određenim kriterijima formira skup jedinki predviđenih za križanje (*mating pool*). Korištenjem definiranih *operatora križanja* (*crossover operator*) dobiva se nova generacija $T+1$. Provedbom mutacije postiže se konačna struktura nove generacije.

Odabir jedinki za križanje, način križanja i formiranje nove generacije može biti različito izvedeno i otvara čitav raspon mogućnosti genetskih algoritama.

U tablici VI. prikazano je elementarno funkcioniranje genetskog algoritma na primjeru traženja maksimuma funkcije $f(x) = x^2$, za cjelobrojnu vrijednost $x \in [1,31]$ [15]. Populacija se sastoji od 4 kromosoma s 5 gena odnosno skup rješenja obuhvaća 4 binarna niza od 5 karaktera. Početna populacija je slučajno odabrana. Odabir jedinki za križanje je napravljen na temelju njihove funkcije prikladnosti. Jedinka s većom funkcijom prikladnosti ima i razmjerno veću vjerojatnost da bude izabrana. To je slikovito predloženo ruletom na slici 20. Za križanje su odabrane jedinke 1, 2 (dva puta) i 4. Njihovi partneri su slučajno odabrani kao i mjesta križanja u kromosomu.




Slika 19. Stvaranje nove generacije

Tablica VI. Primjer funkcioniranja genetskog algoritma

Jedinka-kromosom br.	Početna populacija (sl. odabr.)	fenotip	Funkcija prikad. $f(x)$	Vjerojat. pojave jedinke i $f_i/(\sum f)$	Očekivani broj jedinki f_i/f_{pr}	Stvarni broj jedinki (rulet)
1	01101	13	169	0.14	0.58	1
2	11000	24	576	0.49	1.97	2
3	01000	8	64	0.06	0.22	0
4	10011	19	361	0.31	1.23	1

Tablica VI. (nastavak)

Jedinke odabr. za križanje	Jedinka partner (sl. odabr.)	Mjesto križanja (sl. odabr.)	Nova populacija	Fenotip	Funkcija prikad. $f(x)$
0110 1	2	4	01100	12	144
1100 0	1	4	11001	25	625
11 000	4	2	11011	27	729
10 011	3	2	10000	16	256



Slika 20. Vjerojatnost odabira jedinke za križanje ruletom

Konkretna primjena genetskih algoritama u planiranju gradskih srednjenaponskih razdjelnih mreža je opisana u [38].

Glavni koraci genetskog algoritma su [14]:

Korak 1: $t:=0$, odredi početnu populaciju $Pop(0)$ i procijeni prikladnost svake jedinke;

Korak 2: Ako su ispunjeni kriteriji za završetak, onda je KRAJ;

Korak 3: Odaberi 2 jedinke roditelja iz $Pop(t)$ za križanje, izvrši mutaciju potomaka s određenom vjerojatnošću, izvrši procjenu prikladnosti potomaka;

Korak 4: Ako nije kreirano dovoljno potomaka idi na 3;

Korak 5: Odredi novu populaciju $Pop(t+1)$;

Korak 6: $t=t+1$, idi na 2.

5.3.3. Nedoizvoljeno pretraživanje (tabu search)


U osnovnim crtama je opisana metoda nedozvoljenog pretraživanja (tabu search) [11,12,13,26]. Ona je zajedno sa stohastičkom relaksacijom i genetskim algoritmima u izvještaju Komiteta za operacijska istraživanja u slijedećem desetljeću (Committee on the Next Decade of Operations Research (CONDOR 1988)) označena kao izvanredno obećavajuća u rješavanju praktičnih problema [13].

Osnovna forma nedozvoljenog pretraživanja se bazira na idejama koje je predložio F. Glover (termin *tabu* se prvi put javlja u F. Glover "Future Paths for Integer Programming and Links to Artificial Intelligence", Computers and Operations Research, Vol. 13, pp. 533-549, 1986). Metoda se temelji na procedurama osmišljenim da prijeđu granice prihvatljivosti ili lokalne optimalnosti, koje se obično tretiraju kao ograde. Rani, početni primjeri ovih procedura (izvedenih iz *metoda nadomjesnih ograničenja* (*surrogate constraint methods*) i *pristupa odsijecajućih ravnina* (*cutting plane approaches*)) sistematično dodaju i dokidaju ograničenja omogućujući istraživanje drugih, zabranjenih dijelova prostora rješenja. Neke poticajne ideje se nalaze i u radovima P. Hansena odnosno metodi koju je nazvao *metoda najstrmijeg porasta/najblažeg pada* (*steepest ascent/mildest descent method*) [13].

U radu u kojem se prvi put javio termin *tabu* upotrijebljen je i termin *metaheuristika* (*metaheuristic*) (grč. *metá* - dolazi kao prefiks u mnogim složenicama i znači: usred, među, s, uz, pored, prema, iza, preko, iznad). Metaheuristika označava glavnu strategiju koja usmjerava i modificira druge heuristike da daju rješenja osim onih koja se normalno generiraju u traženju lokalnih optimuma. Heuristike upravljane metaheuristikom mogu biti u rasponu od vrlo jednostavnih do vrlo složenih.


R4

Lokalna procedura je pretraživanje koje koristi operaciju nazvanu *pomak* (*move*) da definira *okolinu*, *susjedstvo* (*neighborhood*) bilo kojeg razmatranog rješenja $\mathbf{N}(\mathbf{x})$. Na slici 21. je simbolički prikazana okolina $\mathbf{N}(\mathbf{x})$ nekog trenutnog rješenja $\mathbf{x}$ u prostoru rješenja $\mathbf{X}$. Neka je $\mathbf{M}=\{m_1, \dots, m_k\}$ skup k *pomaka* te neka primjena pomaka na prihvatljivo rješenje $\mathbf{x} \in \mathbf{X}$ vodi na k obično različitih rješenja $\mathbf{M}(\mathbf{x})=\{\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^k\}$. Podskup *prihvatljivih* rješenja $\mathbf{N}(\mathbf{x}) \subseteq \mathbf{M}(\mathbf{x})$ zove se *okolina* od $\mathbf{x}$.



Slika 21. Okolina $\mathbf{N}(\mathbf{x})$ rješenja $\mathbf{x}$ u prostoru $\mathbf{X}$

Od svih mogućih pomaka iz trenutnog prihvatljivog rješenja $\mathbf{x}$ procedura lokalnog pretraživanja odabire onaj koji najviše poboljšava funkciju cilja, npr. m_i . Zato novo trenutno rješenje postaje $\mathbf{x}^i$. Jedan slijed pretraživanja kojim se stiže do optimalnog, najčeće lokalnog, rješenja $\mathbf{x}^0$ je predložen na slici 22.



Slika 22. Lokalno pretraživanje iz rješenja $\mathbf{x}$ prema $\mathbf{x}^0$

Nedozvoljeno pretraživanje je metaheuristika koja usmjerava procedure lokalnog heurističkog pretraživanja na istraživanje prostora rješenja izvan lokalnih optimuma.

Jedno od glavnih svojstava nedozvoljenog pretraživanja je *prilagodljiva memorija* (*adaptive memory*) koja kreira fleksibilnije ponašanje pretraživanja. Stoga su strategije zasnovane na korištenju memorije zaštitni znak nedozvoljenog pretraživanja.

Budući da se lokalni pomaci realiziraju na osnovi informacija dobivenih iz ukupnog pretraživanja, nedozvoljeno pretraživanje je u opreci s metodama koje ne koriste memoriju, ali i s krutim metodama koje koriste memoriju kao su što su metode grana i granica.

Strukture memorije u metodi nedozvoljenih pretraživanja baziraju se na četiri osnovna aspekta: *recentnosti* (*recency*), *frekvenciji* (*frequency*), *kvaliteti* (*quality*) i *utjecaju* (*influence*). Metode zasnovane na recentnosti i frekvenciji su komplementarne. Dimenzija kvalitete se odnosi na sposobnost razlikovanja vrijednosti rješenja dobivenih za vrijeme pretraživanja. Utjecaj se odnosi na upliv izbora načinjenih za vrijeme pretraživanja ne samo na kvalitetu nego i na strukturu rješenja.

Memorija koju koristi nedozvoljeno pretraživanje može biti *eksplicitna* (*explicit*) i *atributivna* (*attributive*). Eksplicitna memorija bilježi kompletna rješenja, koja se u principu sastoje od najboljih dobivenih tijekom pretraživanja. Proširenja ove memorije bilježe i visokoprivlačne ali neistražene susjede najboljih rješenja, a memorirana najbolja rješenja se koriste za proširenje lokalnih pretraživanja. Atributivna memorija služi za vođenje pretraživanja. Ovaj tip memorije pamti informacije o atributima rješenja koja se mijenjaju prijelazom, pomakom iz jednog u drugo rješenje.

Kao ishodišna točka razmatranja nedozvoljenog pretraživanja može uzeti njegova usporedba s jednostavnim metodama najvećeg pada (u slučaju traženja minimuma). Metode bazirane na najvećem padu, iako istražuju okolinu $\mathbf{N}(\mathbf{x})$ (odabirući najčešće ono susjedno rješenje koje najviše poboljšava funkciju cilja), imaju vrlo ograničen uspjeh u rješavanju teških kombinatoričkih problema. To je razlog što su se javile i metode koje koriste drugačiji kriterij od najvećeg poboljšanja tekućeg rješenja. Neke od njih koriste vjerojatnosni pristup u pretraživanju prostora rješenja sve dok kriteriji zaustavljanja nisu ispunjeni. Tu spadaju genetski algoritmi, stohastička relaksacija, metode s višestrukim startom i metode s drugim formama iterativnog poboljšanja. Nedozvoljeno pretraživanje, za razliku od ovih metoda, koristi drugačiji pristup, baziran prije svega na inteligentnijem pretraživanju prostora rješenja.

Nedozvoljeno pretraživanje koristi dva tipa memorije: *kratkoročnu* i *dugoročnu memoriju*. Svaki tip memorije je pridružen svojim vlastitim posebnim strategijama pretraživanja. Ipak, efekt oba tipa memorije može se sagledati kao modifikiranje okoline $\mathbf{N}(\mathbf{x})$ tekućeg rješenja $\mathbf{x}$. Modificirana okolina, koja se označuje kao $\mathbf{N}^*(\mathbf{x})$, je rezultat pamćenja odabranih stanja obrađenih tokom pretraživanja.

U strategijama nedozvoljenog pretraživanja zasnovanim na kratkoročnim razmatranjima $\mathbf{N}^*(\mathbf{x})$ je podskup od $\mathbf{N}(\mathbf{x})$ i nedozvoljene klasifikacije služe za identificiranje elemenata $\mathbf{N}(\mathbf{x})$ koji su isključeni iz $\mathbf{N}^*(\mathbf{x})$. U strategijama nedozvoljenog pretraživanja koje uključuju dugoročna razmatranja $\mathbf{N}^*(\mathbf{x})$ se može proširiti da uključuje i rješenja koja se uobičajeno ne nalaze u $\mathbf{N}(\mathbf{x})$. Ovakvim pristupom nedozvoljeno pretraživanje se može sagledati i kao dinamička metoda pretraživanja okoline. To znači da okolina od $\mathbf{x}$ nije statički skup nego skup koji se mijenja prema razvoju pretraživanja.

Za nedozvoljeno pretraživanje je važan izbor odgovarajuće definicije $\mathbf{N}^*(\mathbf{x})$. Radi korištenja memorije, $\mathbf{N}^*(\mathbf{x})$ ovisi o trajektoriji koja se slijedi pri prijelazu iz jednog rješenja u naredno (ili skupa takvih trajektorija, ako se radi o paralelnom procesiranju). Kao polazna točka za bavljenje kratkoročnom memorijom, razmatra se forma memorije uključene u *nedozvoljenu listu* (*tabu list*) $\mathbf{TL}$ koja eksplicitno sadržava t različitih rješenja odnosno $\mathbf{TL} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_t\}$, gdje je $\mathbf{N}^*(\mathbf{x}) = \mathbf{N}(\mathbf{x}) \setminus \mathbf{TL}$ tj. $\mathbf{N}^*(\mathbf{x})$ se sastoji od rješenja koja se ne nalaze na nedozvoljenoj listi.

Ovaj pristup pamćenja kompletnih rješenja (eksplicitna memorija) zahtijeva puno memorije pa se često koristi atributivna memorija bazirana na pamćenju atributa.

Nadalje, kratkoročna memorija se često zasniva na recentnim, nedavnim pretraživanjima. Najčešće upotrebljavana kratkoročna memorija pamti attribute rješenja koji su se mijenjali tokom nedavnih pretraživanja i naziva se *recentna memorija* (*recency-based memory*). Ovo je vrsta memorije koja je u kratkim prikazima nedozvoljenog pretraživanja u literaturi najčešće opisana (iako su njeni brojni aspekti izostavljeni u popularnim sažecima). Da bi se ova memorija iskoristila, odabrani atributi koji se pojavljuju u rješenjima koja su zadnja pretražena označavaju se kao *nedozvoljeno aktivna* (*tabu active*), a rješenja koja sadržavaju nedozvoljeno aktivne elemente ili pojedine kombinacije ovih atributa postaju nedozvoljena. Ovo spriječava određena rješenja iz nedavne prošlosti tj. ona nedavno pretražena da postanu dio skupa $\mathbf{N}^*(\mathbf{x})$ te da ne budu ponovo ispitivana. Dok se nedozvoljenost striktno odnosi na rješenja zabranjena za ponovno razmatranje, na temelju sadržavanja nedozvoljeno aktivnih atributa (ili općenitije narušavanjem određenih ograničenja zasnovanih na ovim atributima) često se pomaci koji dovode do ovakvih rješenja označavaju nedozvoljenima.

Broj iteracija tokom kojih se neki atribut drži nedozvoljenim zove se *trajanje nedozvoljenog statusa* (*tabu tenure*). Trajanje nedozvoljenog statusa može varirati za različite tipove ili kombinacije atributa kao i za različite intervale ili faze pretraživanja. Ovo promjenjivo trajanje nedozvoljenog statusa omogućuje stvaranje različitih odnosa između kratkoročnih i dugoročnih strategija. Također, osigurava dinamičku i robustnu formu pretraživanja.

Izbor odgovarajuće nedozvoljene liste ovisi o kontekstu. Iako ne postoji jedinstveni tip liste koji bi bio najbolji za sve aplikacije, ipak se mogu istaći neka načela. Ako postoji dovoljno memorije da se zapamti jedan dio informacije (npr. cjelobrojni broj) za svaki atribut rješenja koji se koristi da aktivira neko pravilo za definiranje nedozvoljenog statusa, obično je prednost zapamtiti brojeve iteracije kada neki atribut postaje i prestaje biti nedozvoljeno aktivan. Potrebna memorija ovisi o atributima i veličini okoline, ali ne i o trajanju nedozvoljenog statusa. Ovaj način memorijske strukture općenito nije prikladan kada veličina problema raste ili se koriste složenije definicije atributa. U tom slučaju se koriste slijedne ili kružne nedozvoljene liste koje sadržavaju identitete nedozvoljeno aktivnih atributa i eksplicitno ili implicitno (prema poziciji na listi) bilježe pridružena vremena trajanja nedozvoljenog statusa.

Djelotvorna trajanja nedozvoljenog statusa mogu se za različite probleme odrediti malim eksperimentiranjem. Trajanja nedozvoljenog statusa koja su premalena prepoznaju se po periodičkom ponavljanju vrijednosti funkcije cilja ili drugim pokazateljima funkcije cilja, uključujući i one generirane *sažimanjem* (*hashing*) koje sugerira pojavu kruženja. Trajanja nedozvoljenog statusa koja su prevelika prepoznaju se po pogoršavanju kvalitete pronađenih rješenja (u odgovarajućem vremenu). Prema tome, između ovih granica nalazi se robustan raspon vrijednosti trajanja nedozvoljenog statusa koji osigurava dobar rad metode.

Općenito, kratka vremena trajanja nedozvoljenog statusa omogućuju ispitivanje rješenja bliskih lokalnom minimumu dok duga vremena trajanja nedozvoljenog statusa doprinose izbjegavanju blizine lokalnog minimuma. Variranjem trajanja nedozvoljnog statusa tijekom pretraživanja osigurava se ravnoteža između uskog pretraživanja jednog područja i kretanja prema različitim dijelovima prostora rješenja.

Pri pretraživanju prostora rješenja treba paziti da se ne izbjegnu dobra rješenja. U tu svrhu se koristi *kriterij poželjnosti* (*aspiration criteria*) koji omogućuje da se neki nedozvoljeni pomaci, ako ispunjavaju određene uvjete, tretiraju kao dozvoljeni. Ti pomaci odnosno rješenja koja se nijma dobivaju čine skup poželjnih rješenja $AL \subseteq TL$. Prikadna upotreba ovakvog kriterija može biti vrlo važna da metoda nedozvoljenog pretraživanja postigne svoju najbolju razinu djelotvornosti. Početne, rane aplikacije koristile su samo jednostavni tip kriterija poželjnosti koji se sastojao od uklanjanja nedozvoljenog statusa pomaku kada bi on davao rješenje bolje nego najbolje do tada. Ovaj kriterij je ostao i dalje u širokoj upotrebi. Međutim, drugi kriteriji poželjnosti su se pokazali djelotvorniji za poboljšanje pretraživanja.

Prva faza razvoja metode nedozvoljenog pretraživanja ili *metoda jednostavnog nedozvoljenog pretraživanja* STL (*simple tabu search*) se zasniva na korištenju:

- a) kratkoročne memorije
- b) nedozvoljene liste
- c) kriterija poželjnosti.

Metoda jednostavnog nedozvoljenog pretraživanja, u slučaju traženja minimuma, može se opisati u 8 koraka:

- Korak 1:** $TL = \emptyset$, $AL = \emptyset$;
- Korak 2:** $k=0$, odaberi početno rješenje $x \in X$, $x'' := x$;
- Korak 3:** Odredi $x' \in \{N(x) \setminus TL \cup AL\}$;
- Korak 4:** $x := \operatorname{argmin} [f(x')]$;
- Korak 5:** Ažuriraj TL ;
- Korak 6:** Ako je $f(x) < f(x'')$ onda $x'' := x$;
- Korak 7:** $k=k+1$;
- Korak 8:** Ako su ispunjeni kriteriji za završetak, onda je KRAJ. Inače idi na 3.

Broj iteracija je označen s k , a x'' predstavlja najbolje postignuto rješenje.

Druga faza razvoja metode nedozvoljenog pretraživanja uključuje *strategije intenziviranja* (*intensification*) i *proširenja* (*diversification*) te *dugoročnu memoriju* (*longer term memory*). Strategije intenziviranja su bazirane na modificiranju izbornih pravila u svrhu pojačanja kombinacija pomaka i osobina rješenja koja su utvrđena kao dobra. Mogu inicirati povratak na privlačane dijelove prostora pretraživanja. Budući da se najbolja rješenja pamte da bi se istražila njihova neposredna okolina, eksplicitna memorija je blisko vezana za primjenu intezivirajućih strategija. Strategije proširenja, s druge

strane, potiču pretraživanje neistraženih dijelova prostora rješenja i generiranje rješenja koja imaju različite osobine od prethodno pronađenih. Ako nema intenziviranja pretraživanje postaje iterativni slučajni proces, a ako nema proširenja može ostati u podoptimalnom području prostora rješenja.

Konačno u trećoj fazi razvoja metode, nedozvoljeno pretraživanje uključuje dodatne mehanizme i osobine kao što su *ponovno povezivanje staza* (*path-relinking*), *elitne konfiguracije* (*elite configuration*), *inteligentni odabir početne konfiguracije* (*intelligent initial configuration selection*), *strateške oscilacije* (*strategic oscillations*), *reduciranje okoline* (*neighborhood reduction*) i *hibridne verzije* u kojima se koriste neke karakteristike drugih kombinatoričkih metoda.

5.3.4. Primjeri drugih aproksimativnih metoda

Navedeno je još nekoliko aproksimativnih metoda za rješavanje kombinatoričkih problema [14,37]:

- memetički (imitacijski) algoritmi (memetic algorithms)
- metoda zadovoljenja ograničenja (constraint satisfaction)
- raspršeno pretraživanje (scatter search)
- sustav kolonije mrava (ant colony system)
- umjetne neuronske mreže (artificial neural networks)
- umjetni imuni sustavi (artificial immune systems)
- usmjereno lokalno pretraživanje (guided local search)
- varijabilno pretraživanje okoline (variable neighborhood search) itd.

6. PROGRAMSKI PAKETI ZA OPTIMALNO PLANIRANJE I PRETPOSTAVKE ZA NJIHOVU PRIMJENU

6.1. Programski paketi za planiranje SN razdjelnih mreža

Jedan popis komercijalnih programskih paketa za planiranje razdjelnih mreža dan je u tablici VII. [25]. Karakteristika navedenih softvera je da obuhvaćaju bazu podataka s tehničkim i prostornim (grafičkim) podacima razdjelne mreže te imaju niz programskih modula za izvršavanje raznih aplikacija. Jedna ili više od njih se odnose i na planiranje srednjenaponske razdjelne mreže. Pri tome neki moduli za planiranje koriste samo razne funkcije planiranja, a neki obuhvaćaju kodirane metode za planiranje i to često varijantne.

U međuvremenu je većina navedenih programskih paketa upotpunjena novim modulima i poboljšanim metodama rješavanja. Osim toga, postoje i drugi softveri za planiranje mreža, a razvijen je i čitav niz novih programskih paketa. Praktički, gotovo u svakoj evropskoj zemlji postoji jedan ili više vlastitih programskih paketa za planiranje srednjenaponskih razdjelnih mreža.

Kod nas su razvijena i koriste se, u svojoj osnovnoj i proširenim verzijama, dva programska paketa za *planiranje* srednjenaponskih razdjelnih mreža CADDiN i PRM [24,33]. CADDiN je namijenjen za planiranje gradskih mreža. Za optimiranje konfiguracija srednjenaponskih vodova koristi genetski algoritam. PRM se zasniva na varijantnom pristupu planiranju s potpunim modelom mreže i uključenom dinamikom. U varijantnom pristupu planer sam interaktivno definira varijante razvoja mreže.

Od stranih programa, koristi se PRAO koji se također zasniva na varijantnom pristupu planiranju. Međutim, radi ilustracije na primjeru PRM-a, pokazaje se koliko je značajna živa interakcija autora s potencijalnim korisnicima te uvažavanje sugestija i specifičnih lokalnih zahtjeva pri kreiranju programa.

Tablica VII. Programski paketi za planiranje razdjelnih mreža

Programski paket	Tvrtka	Zemlja
SIDAC	ASINELSA	Argentina
DMS	CAE Electronics	Kanada
CableCAD, ENGEN	Enghouse	Kanada
AIDPRI	Catholic University of Chile	Čile
Spard	Energy Computer Graphics	Kolumbija
Xpower	Tekla	Finska
MAESTRO	Tietosavo	Finska
Optima	Versoft	Finska
PRAO	EDF	Francuska
IONN	TWS, Saarland University	Njemačka
ODIN	TWS, Saarland University	Njemačka
SINCAL	Siemens	Njemačka
Network Module	ENEL	Italija
Netbas	EFI	Norveška
SGD	Union Fenosa Acex	Španjolska
Svednet, Succél	Kraftdata	Švedska
EnerGIS	Sydkraft	Švedska
NEPLAN 2000	Busarello+Cott+Partner	Švicarska
DINIS	ICL	Velika Britanija
OCEPS	OCEPS	Velika Britanija
CADPAD	ABB	SAD
Cymdist, CYMDPA	CYME	SAD
DEW	EPRI	SAD
WindMil	Milsoft	SAD
JDPE, DistOps, TOR	Miner&Miner	SAD
PSS/U	Power Technologies	SAD
DPA/G	Stoner Associates (Scott&Scott)	SAD
AEDP, DFO, DCP	Tellus	SAD

6.2. Pretpostavke za primjenu programa za optimalno planiranje

Čim je model mreže potpuniji i primijenjena metoda rješavanja optimalna ili što bliža optimalnoj dobivaju se kvalitetniji rezultati odnosno razvoj razdjelne mreže s najmanjim mogućim troškovima za zadani porast opterećenja. Zato je vrlo važno usavršavati i u postojećim modelima planiranja koristiti što bolje optimizacijske metode. Nadalje, i sama upotreba potpunijih modela planiranja mreže implicira složeniju matematičku strukturu optimizacijskog problema koja zahtijeva povećanu djelotvornost metoda rješavanja.

Uspješno korištenje metoda za planiranje srednjenaponskih mreža podrazumijeva postojanje odgovarajućih grafičkih baza podataka. U nedostatku integralnih baza podataka distribucijskog sustava veliki dio programskih paketa za planiranje ima svoje vlastite. Radi izbjegavanja redundancije, osiguranja potpunijeg i bržeg dostupa podacima važno je poraditi na realizaciji AM/FM/GIS grafičkih sustava u okruženju kojih bi programi za optimalno planiranje bili samo jedna od aplikacija.

Rezultati prognoze opterećenja su jako važni za ukupan ishod planiranja razvoja mreže. Zato treba kontinuirano usavršavati metode prognoze.

Točni i ažurni pokazatelji o postojećim opterećenjima i zapisi o njihovim promjenama u prethodnom razdoblju imaju bitan utjecaj na kvalitetu prognoze konzuma. Stoga je neophodno imati dobro provedena i obrađena mjerenja.

Cijene elemenata mreže, radova, gubitaka i neisporučene električne energije moraju biti što preciznije utvrđene. Pri tome je praktično jedini, ali vrlo značajan problem određivanja troškova neisporučene električne energije. Nadalje, samo objektivno razmatranje pouzdanosti pri planiranju podrazumijeva kvalitetno registriranje i obradu pogonskih događaja.

Što se tiče dereguliranog okruženja, treba istaknuti da principi optimalnosti razdjelne mreže univerzalno vrijede.

7. ZAKLJUČAK

Razdjelna elektroenergetska mreža predstavlja složenu tehničku i ekonomsku funkcionalnu cjelinu u kojoj već vrlo mali postoci ušteda znače jako velike apsolutne iznose. Planiranje je faza u sklopu ukupnih aktivnosti vezanih za pripremu građenja, samu izgradnju i rad mreže u kojoj se mogu ostvariti daleko najveće uštede i zato zahtijeva primjeren tretman. Stoga je od velike važnosti što se metode optimizacije, zahvaljujući usavršavanju postojećih i razvoju novih, uz sve snažniju računalnu podršku mogu djelotvorno primijeniti u planiranju mreža.

U radu je dan pregled i opisani osnovni principi najznačajnijih metoda za optimalno planiranje elektroenergetskih srednjenaponskih razdjelnih mreža. U tu svrhu je definiran odgovarajući matematički model planiranja srednjenaponske mreže i prikazana njegova struktura. Opisane su troškovne karakteristike napojnih transformatorskih stanica i srednjenaponskih vodova kao najvažnijih elemenata mreže. Pokazano je kako opseg elemenata koje obuhvaća model planiranja i stupanj detalja kojim su opisani utječe na složenost optimizacijskog problema i odabir odgovarajuće metode rješavanja.

S obzirom da problem određivanja optimalnih lokacija i veličina napojnih transformatorskih stanica te trasa srednjenaponskih vodova predstavlja sa stanovišta rješavanja složen problem, primjena točnih metoda je ograničena na mreže manjih dimenzija. Zato je naglasak dan na prezentiranje aproksimativnih metoda kao što su stohastička relaksacija, genetski algoritam i nedozvoljeno pretraživanje. Kako se radi o metaheurističkim metodama opće namjene, s vrlo širokom primjenom u raznim oblastima, opisane su ideje na kojima se zasnivaju i osnovni principi njihova rada.

Dan je pregled nekih komercijalnih programskih paketa za planiranje srednjenaponskih razdjelnih mreža. Na temelju dosadašnjih iskustava i činjenice da gotovo sva značajnija elektroprivredna odnosno elektrodistribucijska poduzeća raspolažu i "svojim" programima za planiranje, treba istaknuti značaj stalnog usavršavanja postojećih programa i metoda optimiranja u vlastitoj sredini.

U svrhu izbjegavanja redundancije podataka zbog korištenja drugih vrsta aplikacija vezanih uz distribucijski sustav te radi njihovog bržeg i točnijeg zahvata nužno je poraditi na tipskoj bazi podataka elemenata razdjelne mreže u GIS okruženju. Također je potrebno imati obrađene podatke o odgovarajućim mjerenjima i pogonskim događajima.

LITERATURA

- [1] Aarts E., Korst J.:
"Simulated Annealing and Boltzmann Machines", John Wiley & Sons, Chichester, 1989.
- [2] Bäck T.:
"Evolutionary Algorithms in Theory and Practice", Oxford University Press, Oxford, 1996.
- [3] Bäck T., Fogel D., Michalewicz Z.:
"Handbook of Evolutionary Computation", Institute of Physics Publishing, Bristol & Oxford University Press, Oxford, 1997.
- [4] Ball M., Magnanti T., Monma C., Nemhauser G.:
"Handbooks in operations research and management science (Volume 8: Network routing)", Elsevier, Amsterdam, 1995.
- [5] Bansal R.:
"Bibliography on the Fuzzy Set Theory Applications in Power Systems (1994-2001)", IEEE Trans. on Power Systems, Vol. 18, No. 4, November 2003, pp. 1291-1299.
- [6] Billinton R., Allan R.:
"Reliability Evaluation of Power Systems", Plenum Press, New York, 1996.
- [7] Cox E.:
"The Fuzzy System Handbook", Academic Press, Boston, 1994.

R4

- [8] Crawford M., Holt B.:
"A mathematical optimization technique for locating and sizing distribution substations, and deriving their optimal service areas ", IEEE Trans., Vol. PAS-94, No. 2, Mar./Apr. 1975, pp. 230-235.
- [9] Davis L.:
"Genetic Algorithms and Simulated Annealing ", Pitman Publishing, London, 1987.
- [10] Fogel D.:
"Evolutionary Computation ", IEEE Press, Piscataway, NJ, 1995.
- [11] Glover F.:
"Tabu Search - Part I", ORSA Journal on Computing , Vol. 1, No. 3, 1989, pp.190-206.
- [12] Glover F.:
"Tabu Search - Part II", ORSA Journal on Computing , Vol. 2, No. 1, 1990, pp. 4-32.
- [13] Glover F., Laguna M.:
"Tabu Search", Kluwer Academic Publishers, Dordrecht, 1997.
- [14] Glover F., Kochenberger G.:
"Handbook of metaheuristics", Kluwer Academic Publishers, Dordrecht, 2003.
- [15] Goldberg D.:
"Genetic Algorithms in Search, Optimization, and Machine Learning ", Addison-Wesley Publishing Company, Reading, Massachusetts, 1989.
- [16] Gönen T., Ramirez-Rosado I.:
"Review of distribution system planning models: a model for optimal multistage planning ", IEE Proc., Vol. 133, Pt. C, No. 7, November 1986, pp. 397- 408.
- [17] Grimsdale L., Sinclair H.:
"The design of housing-estate distribution systems using a digital computer", Proc. IEE, Vol. 107 A, 1960, pp. 295-305.
- [18] Kariuki K., Allan R.:
"Evaluation of reliability worth and value of lost load", IEE Proc. - Gener. Transm. Distrib., No. 2, March 1996, pp. 171-180.
- [19] Khator S., Leung L.:
"Power Distribution Planning: A Review of models and Issues", IEEE Trans. on Power Systems, Vol. 12, No. 3, August 1997, pp. 1151-1159.
- [20] Kirpatrick S, Gelatt C., Vecchi M.:
"Optimization by Simulated Annealing ", Science Vol. 220, No. 4598, 13 May 1993, pp. 671-680.
- [21] Knight U.:
"The logical design of electrical networks using linear programming methods", Proc. IEE, Vol. 107 A, 1960, pp. 306-314.
- [22] Kosko B.:
"Neural Networks and Fuzzy Systems", Prentice Hall, Englewood Cliffs, 1992.
- [23] Krajcar S.:
"Algoritmi za interaktivno optimalno planiranje razdjelnih mreža", doktorska disertacija, ETF Zagreb, Zagreb 1988.

- [24] Krajcar S., Škrlec D.:
"CADDIN - Programski paket za optimalno planiranje razdjelnih mreža ", referat,
XX. savjetovanje JUKO CIGRE, Grupa 31, Neum, 22.04.-26.04.1991.
- [25] Lakervi E., Nurmi M.:
"Present status in applying mathematical planning methods in AM/FM-GIS systems", Proc. of
14th International Conference on Electricity Distribution, CIRED' 97, Birmingham, 2-5 June,
1997, Session 6, Paper No 24.
- [26] Løkketangen A.:
"Tabu Search as Metaheuristic Guide for Combinatorial Optimization Problems", Ph. Thesis,
Institute for Informatics, University of Bergen, Norway, 1995.
- [27] Martić Lj.:
"Matematičke metode za ekonomske analize 2", Narodne novine, Zagreb, 1979.
- [28] Miranda V., Proença L.:
"Probabilistic choice vs. risk analysis – conflicts and synthesis in power system planning",
IEEE Trans. on Power Systems, Vol. 13, No. 3, August 1998, pp. 1038-1043.
- [29] Nemhauser G., Wolsey L.:
"Integer and Combinatorial Optimization", John Wiley & Sons, New York, 1988.
- [30] Plaper M.:
"Principi optimalnosti u mrežama za prenos i distribuciju električne energije", ZJE Beograd,
EI "M.Vidmar" Ljubljana, 1980.
- [31] Pilo F., Allegranza V., Celli G., Cicoria R., Mocci S.:
"An integrated tool for optimal active network planning", Proc. of 17th International Conference
on Electricity Distribution, CIRED' 03, Barcelona, 12-15 May, 2003, Session 5, Paper No 64.
- [32] Rajić Ž.:
"Određivanje optimalnih konfiguracija razdjelnih mreža", Energija, br. 2, 1987., str. 157-166.
- [33] Rajić Ž., Wagmann L.:
"Programski paket za tehnoekonomsku analizu konfiguracija srednjenaponskih distribucijskih
mreža (PRM) ", IE, Zagreb, 1993.
- [34] Rajić Ž., Wagmann L.:
"Programski paket za varijantno planiranje konfiguracija srednjenaponskih razdjelnih mreža
(PRM)", Verzija 2.1, EI "H. Požar", Zagreb, 1996.
- [35] Rajić Ž.:
"Razmatranje pouzdanosti pri planiranju razdjelnih elektroenergetskih mreža", studija,
EI "H. Požar ", Zagreb, 1999.
- [36] Rajić Ž.:
"Mogućnosti korištenja neizrazite logike pri prognoziranju opterećenja malih područja ", Četvrto
savjetovanje HK CIGRE, Ref. 31.25, Cavtat, 17-21. listopada 1999.
- [37] Reeves C.:
"Modern heuristic techniques for combinatorial problems", Blackwell Scientific Publications,
Osney Mead, Oxford, 1993.
- [38] Škrlec D.:
"Planiranje razdjelnih mreža genetskim algoritmima", doktorska disertacija, FER Zagreb,
Zagreb 1996.

R4

- [39] Švajger A.:
"Biologija i reinkarnacija: Genom i klon ", Medicinski fakultet u Zagrebu,
<http://www.vms.hr/school/klon02.htm>
- [40] Temraz H., Quintana V.:
"Distribution system expansion planning models: an overview ", Electric Power Systems Research, Vol. 126, 1993, pp. 61-70.
- [41] Vaziri M., Tomsovic K., Gönen T.:
"Distribution expansion problem revisited. Part 1: Categorical analysis and future directions ",
Proc. of the 4th IASTED International Conference on Power and Energy Systems (PES 2003),
Marbella, Spain, September 19-22, 2000.
- [42] Wei X., Sumić Ž., Venkata S.:
"ADSM - An Automated Distribution System Modeling Tool for Engineering Analyses", IEEE
Trans. on Power Systems, No. 1, February 1995, pp. 393-399.
- [43] Willis H.:
"Spatial Electric Load Forecasting", M. Dekker, New York, 1996.
- [44] Willis H.:
"Power Distribution Planning Reference Book", M. Dekker, New York, 1997.