Sustav za pomoć pri prostornom odlučivanju u distribuciji

Zaspan, Mihael

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:229392

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA

Sveučilišni studij

SUSTAV ZA POMOĆ PRI PROSTORNOM ODLUČIVANJU U DISTRIBUCIJI

Diplomski rad

Mihael Zaspan

Osijek, 2017.

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac D1: Obrazac za imenovanje Povjerenstva za obranu diplomskog rada

Osijek, 22.09.2017.

Odboru za završne i diplomske ispite

Imenovanje Povjerenstva za obranu diplomskog rada

Ime i prezime studenta:	Mihael Zaspan
Studij, smjer:	Diplomski sveučilišni studij Elektrotehnika
Mat. br. studenta, godina	D 913, 12.10.2015.
OIB studenta:	64011401766
Mentor:	Doc.dr.sc. Krešimir Fekete
Sumentor:	
Sumentor iz tvrtke:	Dr.sc. Slaven Kaluđer
Predsjednik Povjerenstva:	Izv. prof. dr.sc. Zvonimir Klaić
Član Povjerenstva:	Doc.dr.sc. Goran Knežević
Naslov diplomskog rada:	Sustav za pomoć pri prostornom odlučivanju u distribuciji
Znanstvena grana rada:	**Elektroenergetika (zn. polje elektrotehnika)**
Zadatak diplomskog rada:	U radu je potrebno prikazati povijesni pregled razvoja sustava za pomoć pri prostornom odlučivanju. Opisati strukturu i metode korištene u razvoju sustava za pomoć pri prostornom odlučivanju, navesti razloge korištenja. Prikazati mogućnosti elektrodistribucijskog sustava za pomoć pri odlučivanju DeGIS (Smallworld, General Electric) na nekoliko slučajeva. Proučiti i opisati GIS funkciju u programu PowerWorld te napraviti usporedbu mogućnosti sa
Prijedlog ocjene pismenog dijela ispita (diplomskog rada):	Vrlo dobar (4)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 2 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 2 bod/boda Jasnoća pismenog izražavanja: 2 bod/boda Razina samostalnosti: 2 razina
Datum prijedloga ocjene mentora:	22.09.2017.

Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis:
	Datum:

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK**

IZJAVA O ORIGINALNOSTI RADA

Osijek, 03.10.2017.

Ime i prezime studenta:	Mihael Zaspan
Studij:	Diplomski sveučilišni studij Elektrotehnika
Mat. br. studenta, godina upisa:	D 913, 12.10.2015.
Ephorus podudaranje [%]:	3%

Ovom izjavom izjavljujem da je rad pod nazivom**: Sustav za pomoć pri prostornom odlučivanju u distribuciji**

izrađen pod vodstvom mentora Doc.dr.sc. Krešimir Fekete

i sumentora

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija.
Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

SADRŽAJ

1. UVOD 1
1.1. Zadatak diplomskog rada 2
2. POVJESNI PREGLED 1
3. GEOGRAFSKI INFORMACIJSKI SUSTAV 3
3.1. Osnova geografskog informacijskog sustava 3
3.2. Struktura GIS-a 6
3.3. Vrste GIS SOFTWARE-a 11
3.4. GIS u elektrodistribuciji 14
4. EKSPERTNI SUSTAV 17
4.1. Umjetna inteligencija 17
4.2. Struktura ekspertnog sustava 20
4.3. Karakteristike ekspertnog sustava 24
4.4. Razvoj ekspertnog sustava 26
5. SUSTAV ZA POMOĆ PRI PROSTORNOM ODLUČIVANJU 29
5.1. Definicija sustava za pomoć pri prostornom odlučivanju 29
5.2. Razvoj sustava za pomoć pri prostornom planiranju 31
5.3. Primjena sustava za pomoć pri prostornom odlučivanju 34
5.4. Budućnost SDSS-a 38
6. REZULTATI 40
6.1. Sustav za pomoć pri prostornom odlučivanju u distribuciji (DeGIS) 40
6.2. GIS funkcija u programskom paketu *PowerWorld* 53
7. ZAKLJUČAK 55
POPIS UPOTREBLJENE LITERATURE 56
SAŽETAK 58
ABSTRACT 58
ŽIVOTOPIS 59

1. UVOD

Distribucija električne energije vrlo je zahtjevan proces. Zbog veličine mreže za distribuciju električne energije te zbog velikog broja elemenata nemoguće je vođenje i održavanje takvog sustava bez pomoći. Čovjek oduvijek traži način kako da si olakša posao. Danas u modernom svijetu ljudi se sve više oslanjaju na pomoć računala i računalnih sustava. Jedan takav sustav je i DeGIS (*Digital energy geographic information system*), sustav za pomoć pri prostornom odlučivanju u distribuciji kojeg koristi HEP Operator distribucijskog sustava. DeGIS objedinjuje geografski informacijski sustav, koji omogućuje korištenje geografskih podataka, te ekspertni sustav koji omogućuje naprednu pretragu.

Sustav za pomoć pri prostornom odlučivanju nastao je iz dva sustava, geografskog informacijskog sustava, te ekspertnog sustava. Evolucija sustava može se podjeliti u tri osnovne faze. U osamdesetim godinama prošlog stoljeća sustav je bio u uvodnoj fazi, nakon toga kroz devedesete godine dolazi do integracije te nakon toga pa sve do danas slijedi faza implementacije.

U diplomskom radu pobliže su objašnjene mogućnosti i način funkcioniranja sustava za pomoć pri prostornom odlučivanju. U prvom djelu rada teorijski je obrađen geografski informacijski sustav i ekspertni sustav. Za svaki od sustava prikazana je te opisana struktura kao i područje primjene. Nakon toga opisan je sustav za pomoć pri prostornom odlučivanju u distribuciji. Teorijski dio odnosi se na definiranje, razvoj te područja primjene sustava. Nakon teorijskog djela na četiri različita slučaja prikazane su mogućnosti sustava za pomoć pri prostornom odlučivanju u distribuciji DeGIS. Prikazivanjem mogućnosti kakve imaju programi poput DeGIS-a želi se istaknuti važnost ovakvih programa u distribuciji električne energije, kao i njihova uloga u bilo kojem području koje je vezano za geografske informacije.

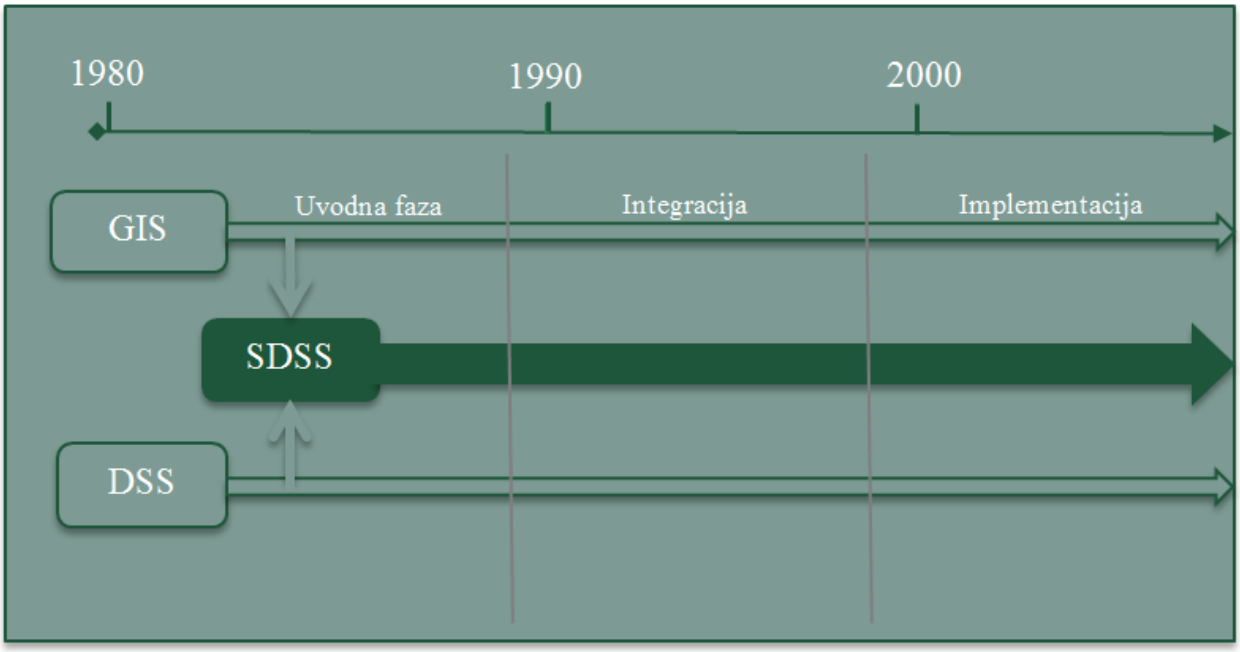
Diplomski rad je podijeljen na sljedeći način: u drugom poglavlju prikazan je povjesni razvoj sustava za pomoć pri prostornom odlučivanju. Treće poglavlje pobliže objašnjava geografski informacijski sustav, kao i njegovu primjenu u distribuciji električne energije. U četvrtom poglavlju objašnjen je ekspertni sustav, te uloga umjetne inteligencije u takvom sustavu. Peto poglavlje opisuje sustav za pomoć pri prostornom odlučivanju. U šestom poglavlju prikazani su grafički rezultati dobiveni u programu DeGIS te usporedba DeGIS-a i GIS funkcije *PowerWorld* simulatora.

1.1. Zadatak diplomskog rada

U radu je potrebno prikazati povjesni pregled razvoja sustava za pomoć pri prostornom odlučivanju. Opisati strukturu i metode korištene u razvoju sustava za pomoć pri prostornom odlučivanju, navesti razloge korištenja. Prikazati mogućnosti elektrodistribucijskog sustava za pomoć pri odlučivanju DeGIS (Smallworld, General Electric) na nekoliko slučajeva. Proučiti i opisati GIS funkciju u programu PowerWorld te napraviti usporedbu mogućnosti sa DeGIS-om. Zaključna razmatranja i trendovi u budućnosti.

2. POVJESNI PREGLED

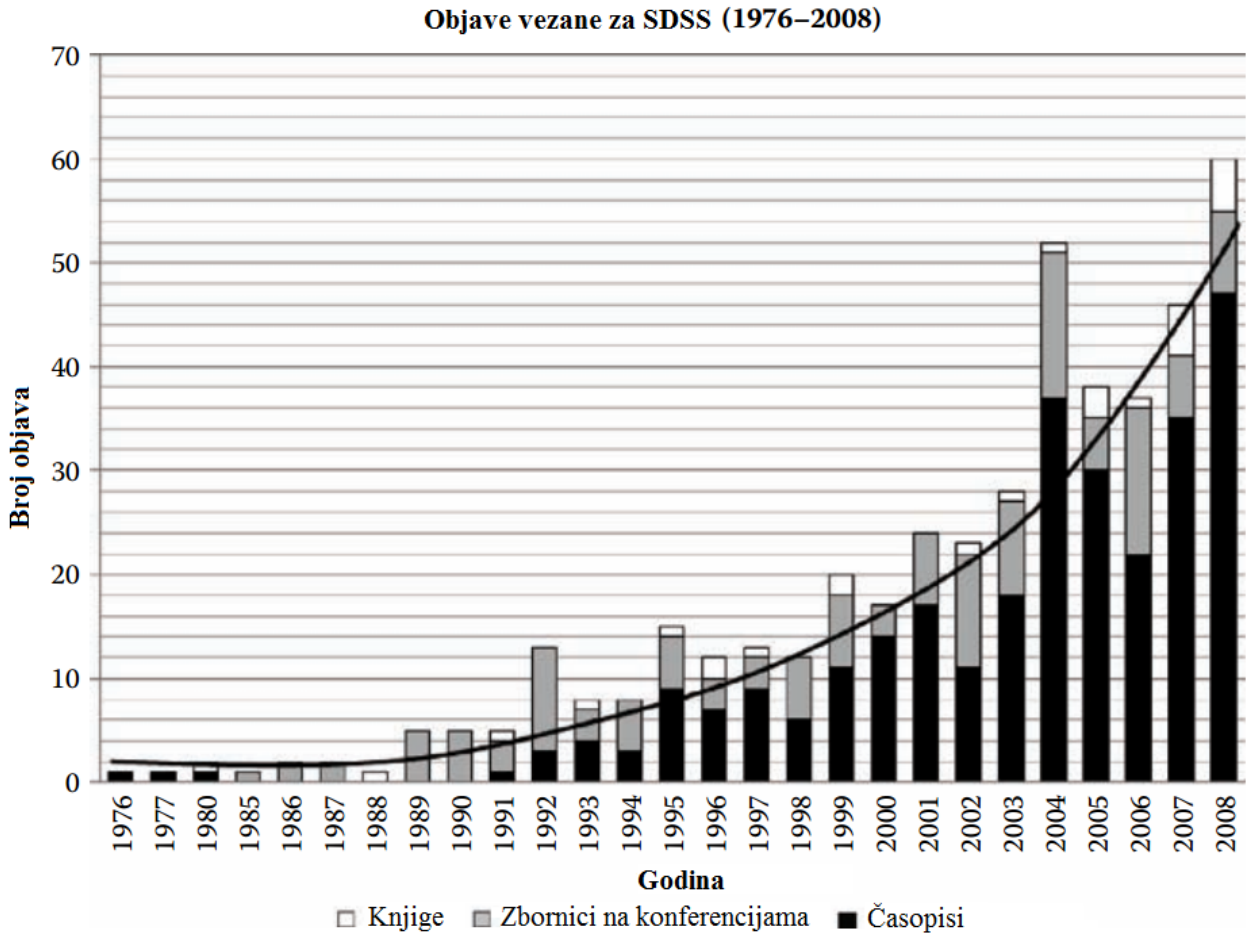
Poglavlje 2 nastalo je prijevodom i obradom iz literature: R. Sugumaran, J. DeGroote, *Spatial Decision Support Systems Principles and Practices*. Sustav za pomoć pri prostornom planiranju (SDSS) osmišljen je kako bi omogućio korisniku okruženje za donošenje odluka pomoću geografskih informacija. U zadnja tri desetljeća SDSS je doživio ogroman rast, te se od samostalne *desktop* aplikacije pretvorio u značajan internetski sustav. U ovome poglavlju opisati ćemo kako se razvijao SDSS. Istraživnje SDSS-a pokazuje da on potječe od dva različita sustava, ekspertnog sustava (DSS) i geografsko informacijskog sustava (GIS). Slika 2.1. prikazuje razvoj SDSS-a iz GIS-a i DSS-a. Svaki od ovih sustava je na svoj način dao doprinos razvoju SDSS-a.



Slika 2.1. Razvoj sustava za odlučivanje (SDSS, DSS i GIS) [1]

Tijekom protekla tri desetljeća postignut je značajan napredak na području informacijskih sustava, uključujući i područje tehnologija za pomoć pri prostornom odlučivanju. Mnogo čimbenika je utjecalo na razvoj, uključujući razvoj informacijskih tehnologija (IT) i komunikacijskih tehnologija (CT). Također značajan utjecaj u razvoj činili su sami ljudi koji kao korisnici prihvaćaju nove tehnologije, ali i programeri koji neprestano gledaju naprijed, te razvijaju bolje i naprednije sustave. Danas su podaci dostupni u financijskom kao i u tehničkom smislu što također olakšava implementaciju ovakvih sustava u društvo.

Na slici 2.2. prikazana je evolucija sustava kroz različite objave vezane za SDSS, gdje je u osamdesetim godinama uvodna faza, tijekom devedesetih je faza integracije, a nakon nje slijedi faza implementacije. Uvodna faza bila bi predstavljanje koncepta SDSS-a, te razvoj prototipa. U fazi integracije u kojoj su zapravo integrirane različite nove tehnologije u sustav. U ovoj fazi razvoj SDSS-a rapidno raste. Posljednja faza je faza implementacije u kojoj je upotreba SDSS-a u velikom porastu. Treba napomenuti kako ipak granice između faza nisu jasno definirane, jer nije bilo oštrih odnosno naglih promjena priilikom razvoja sustava.



Slika 2.2. Prikaz objava vezanih za SDSS [1]

3. GEOGRAFSKI INFORMACIJSKI SUSTAV

3.1. Osnova geografskog informacijskog sustava

Prema literaturi [2]: „GIS (geografski infromacijski sustav) (eng. *geographic information system*) je relativno nov pojam. Pojavio se kada i ostali informacijski sustavi, tj. pojavom računala. Općenito, sustav je skup povezanih objekata i aktivnosti koji svojim međuodnosima služe zajedničkoj namjeni. U GIS-u zajednička namjena je donošenje odluka pri upravljanju nekim prostornim aktivnostima. Informacijski sustav je skup postupaka izvršenih nad skupom podataka kojima se dobiva informacija pogodna za donošenje odluka. GIS možemo smatrati tehnologijom (*hardware* i *software*) ili strategijom za obradu informacija, ovisno o kontekstu. Svrha GIS-a je unaprijediti donošenje odluka koje su na bilo koji način u vezi s prostorom. GIS obrađuje prostorne podatke. Prostorni podaci su informacije povezane s prostornim položajem. Dakle, GIS omogućuje povezivanje aktivnosti koje su prostorno povezane. Osim toga, GIS integrira prostorne i druge vrste informacija unutar jednog sustava te na taj način nudi konzistentni okvir za analizu prostora.“

Geografski informacijski sustavi koriste se još od osamdesetih godina prošlog stoljeća. Osnova sustava je računalni *software-ski* paket koji ima funkcije pohrane, prikazivanja i analize prostornih podataka. *World wide web* (www) uvelike je promjenio način korištenja GIS-a. Do početka ovog stoljeća GIS *software-i* bili su namjenjeni profesionalnoj upotrebi. Obično je GIS bio izolirana tehnologija sa bazom podataka te se koristio unutar granica poduzeća. Razvoj te široka upotreba interneta donjeli su i transformaciju GIS-a te se pojavljuje sve veći broj GIS aplikacija. Komunikacija putem interneta i *web-a* omogućila je povezivanje različitih poduzeća kao i povezivanje odjela unutar nekog poduzeća [3]

Autori u literaturi [2] navode: „Upotreba sustava za upravljanje bazama podataka je vrlo važna za današnju koncepciju GIS-a. Sustav za upravljanje bazama podataka integrira prostorne podatke i podatke koji nisu prostorni, ali su na neki način povezani s prostornim podatcima. Razvoj relacijskih baza podataka je posebno važan, a primjer takve baze je *Oracle* koji je danas u širokoj upotrebi. Ključ za uspostavljanje tehnologije za potrebe donošenja odluka je integracija: povezivanje tehnologije, podataka i strategija donošenja odluka. Ono što je GIS danas jest objedinjavanje tehnika prostornih analiza i digitalnih prostornih podataka s računalnom tehnologijom. No za mnoge GIS je više od računalne baze podataka i skupa alata: to je također filozofija za upravljanje informacijama. Često GIS može biti jezgra upravljanja

informacijama unutar neke organizacije. Postoje i drugi pristupi. U posljednje vrijeme cijelo se područje naziva upravljanjem geografskim informacijama (G*eographic Information Management*, GIM) ili čak geomatikom.“

Na slici 3.1. vidimo tri osnovna djela GIS-a. Dakle GIS se sastoji od prostornih podataka, kojima manipuliramo računalima, odnosno potrebnim *hardware-om* i *software-om*, sve u svrhu pojednostavljenja donošenja odluka.



Slika 3.1. Osnova GIS-a [2]

Prema literaturi [2]: „Unutar informacijskog sustava mogu se upotrijebi različiti tipovi podataka od kojih svaki ima svoje karakteristike. Podatci mogu biti prostorni u smislu da opisuju pojedini položaj neposredno ili posredno. Podatci se mogu prikazati u grafičkom ili negrafičkom obliku. Karte su osnovni izvor podataka za GIS te je kartografska tradicija od fundamentalnog značaja za način na koji GIS funkcionira. Važno je zapamtiti da karte ipak nisu jedini izvori prostornih podataka. Korištenje GIS-a najčešće rezultira nekom od sljedećih radnji:

- unos podataka,
- spremanje podataka,
- upravljanje podatcima,
- analiza podataka,
- ispis rezultata.

Kada se govori o unosu podataka misli se na prikupljanje te pretvaranje podataka u digitalni oblik. To je najčešće najveći problem kod primjene GIS-a, a troškovi mogu biti vrlo veliki. Podaci se općenito spremaju u vektorskom i rasterskom obliku. Svaki od tih oblika ima svoje prednosti i nedostatke. Oblik podataka je vrlo važan i određuje moguće primjene tih podataka unutar sustava. Primjerice, AutoCAD Map i GeoMedia mogu prikazivati oba oblika podataka, ali ne mogu analizirati rasterske podatke. Vrlo važno je efikasno upravljanje velikim količinama podataka ako se želi GIS učiniti isplativim. To je dio koji ovisi o izboru struktura podataka, *hardware-u* i *software-u*. Nikad ne treba podcjeniti vrijeme koje je potrebno za učenje novoga *software-skog* paketa. Kako bi bio od koristi GIS mora moći provoditi široki raspon funkcija za upravljanje i analizu podataka. Snaga GIS-a leži u integraciji različitih tipova podataka. Kvalitetni ispis podataka u različitim oblicima je također vrlo važan za većinu korisnika GIS-a. Ispis može biti u obliku novih skupova digitalnih prostornih podataka, karata, tablica, izvješća.“

U literaturi [2] navedeno je da: „Upotreba programa za GIS i prostornih podataka trebala bi dovesti do boljeg upravljanja informacijama; kvalitetnijih analiza; mogućnosti izrade scenarija i povećanja efikasnosti projekta. Međutim, o dostupnosti podataka ovise mnoga od tih postignuća. Upotrebu GIS-a nalazimo u različitim organizacijama. Tvrtke koje održavaju infrastrukturu, a to su npr. električna, plinska, vodovodna i telefonska mreža, upotrebljavaju GIS za spremanje, pronalaženje i analizu njihovih postrojenja i ostale infrastrukture. GIS može pripomoći pri odnosu s korisnicima, predviđanju, otklanjanu kvarova, planiranju, strategijama i analizama tržišta. Marketing i prodaja primjenjuju GIS za pronalaženje kupaca i potencijala nekog tržišta. Zaštita okoliša također koristi GIS za pomoć kod upravljanja šumama, analize utjecaja, upravljanja prirodnim bogatstvima. Primjer GIS-a u “realnom vremenu” nalazimo u transportu i distribuciji, a upotrebljavaju ga prijevozničke tvrtke i hitne službe koje moraju u svakom trenutku znati gdje im se nalaze vozila. Zdravstvo, kartiranje bolesti kao i epidemiologija, planiranje zdravstvene infrastrukture. Osiguravajuće kuće koriste GIS za analize rizika, planiranje katastrofa, analize usluga korisnicima, predviđanje šteta itd.“

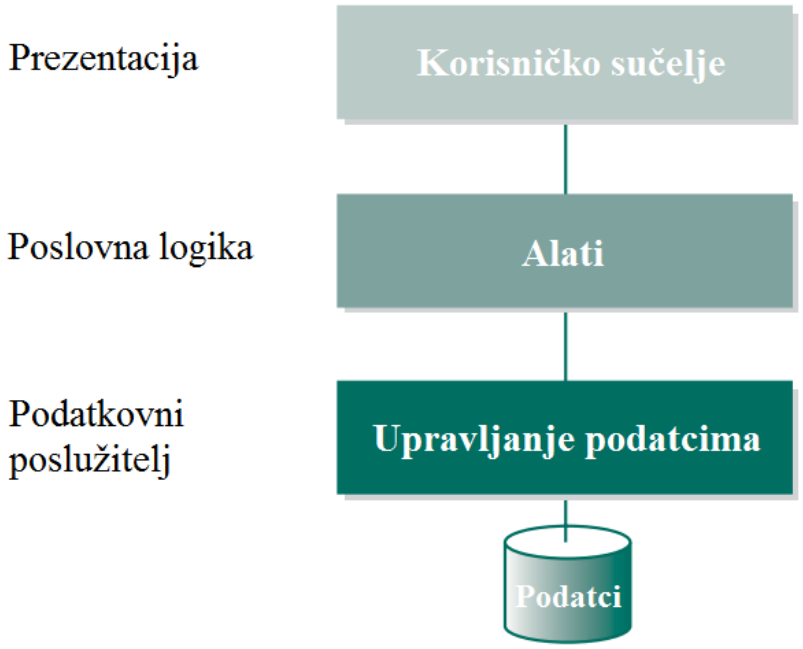
Geografski informacijski sustav sve češće se primjenu u urbanističkom planiranju, upravljanju prirodnim resursima i izradi karata. Najčešći razlog za primjenu GIS-a je pomoć pri odlučivanju i rješavanju problema [4].

3.2. Struktura GIS-a

Geografski informacijski sustav u širem smislu se sastoji od *software-a*, podataka, ljudi te organizacije unutar koje funkcionira. Prema definiciji GIS se uvijek sastoji od modula za unos, pohranu, analizu, prikazivanje i izvoz prostornih podataka. Za pojedini GIS sustav svaki modul ima određenu ulogu, veću ili manju. Međutim, ako bi jedna od tih funkcija bila potpuno isključena sustav se više ne može nazivati GIS-om. [5]

Geografski informacijski sustav u poduzeću se obično koristi za pojedinačni, vremenski ograničeni projekt. Tehničke komponente (mreža, *hardware*, *software* i podatci) operativnog GIS-a sastavljene su tokom projekta, što može značiti nekoliko mjeseci pa i nekoliko godina. Podatci se skupljaju posebno za projekt i obično se ne daje velika pažnja ponovnom iskorištenju *software-a*, podataka, te ljudskog znanja. U velikim kompanijama projekti se mogu odvijati jedan za drugim ili čak istovremeno. Projekt koji je jednokratan u kombinaciji sa lošom vizijom poduzeća dovodi do određenih dupliciranja, jer se svaki projekt razvija pomoću posebnog *hardware-a*, *software-a*, podataka, ljudi i postupaka. Djeljenje odnosno razmjena podataka i iskustva imaju nizak prioritet. Kako zanimanje i korištenje GIS-a raste, zbog ušteda te ponovnog korištenja znanja i resursa, više projekata istog odjela mogu biti spojeni. To najčešće dovodi do razvoja određenih standarda, posebnog GIS tima, te također razvoja novih sposobnosti vezanih za GIS. S druge strane nije rijetkost da različiti odjeli koriste potpuno različite *software-e*. Budući da je GIS postao neizbježan u poslovanju, poduzeća sve više uče o njemu te polako postaju ovisna o njemu. Do toga dovodi spoznaja da GIS može biti korišten u strukturiranju imovine, procesa, kao i tokova radova. Kroz proces prirodnog rasta te mogućnosti dodatnog razvijanja i nadograđivanja, GIS je postao vrlo važan informacijski sustav [6].

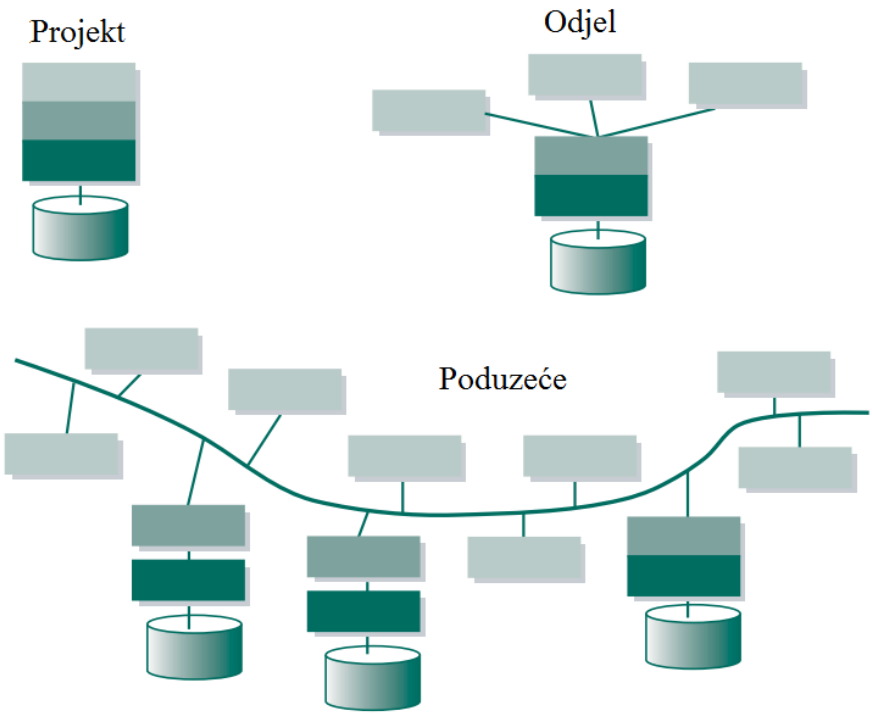
Iz perspektive informacijskih sustava postoje tri osnovna dijela GIS-a: korisničko sučelje, alati i sustav upravljanja podacima. Osnovni dijelovi GIS-a prikazani su na slici 3.2. Interakcija između korisnika i sustava odvije se grafičkim korisničkim sučeljem (*Graphical user interface*, GUI), u koji su integrirani izbornici, alatne trake i druga pomagala [6].



Slika 3.2. Osnovni dijelovi GIS-a [6]

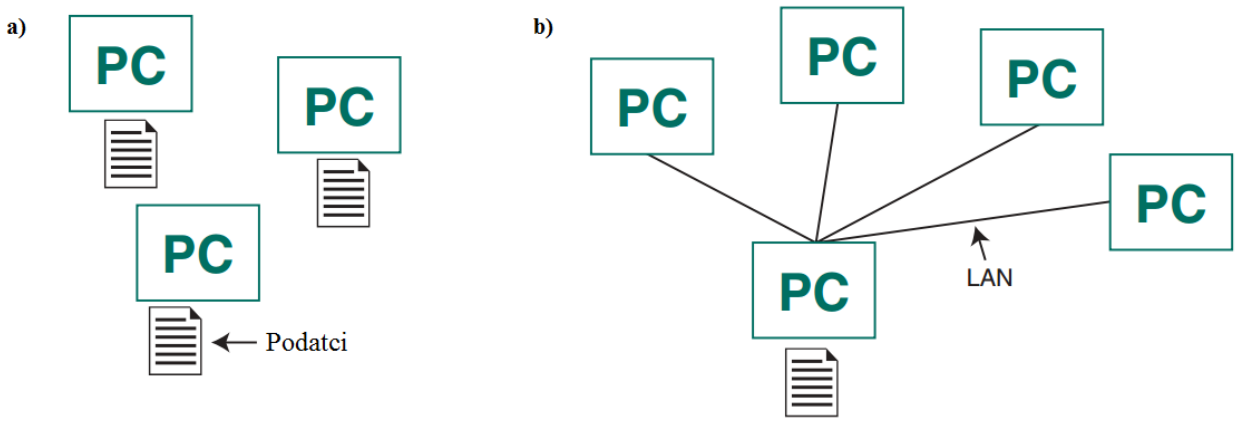
GUI omogućuje pristup alatima GIS-a. Alati određuju funkcije i mogućnosti koje ima GIS *software*. Podaci se pohranjuju u datotekama ili bazama podataka organiziranima pomoću *software-a* za upravljanje podatcima. U informacijskoj terminologiji ovakvu arhitekturu nazivamo troslojnom ili trorazinskom. Tri sloja su: prezentacija, poslovna logika i podatkovni poslužitelj. Svaki od slojeva zadužen je za neovisno obavljanje različitih zadataka. Prezentacijski sloj mora omogućiti prikazivanje i interakciju s grafičkim objektima. Poslovni logički sloj zadužen je za obavljanje složenih računalnih operacija, kao što su obrada podataka i rasterske analize. Sloj podatkovnog poslužitelja mora omogućiti uvoz i izvoz podataka iz baza podataka. Kako bi se maksimiziralo iskorištenje sustava bilo bi korisno optimizirati *hardware* i postavke operativnog sustava posebno za svaku vrstu zadatka. Naprimjer, prikazivanje karata zahtjeva veliku količinu memorije i brze procesore, dok razmjena informacija sa bazama podataka zahtjeva brze tvrde diskove i sabirnice za što veću razmjenu podataka. Postavljanjem pojedinih slojeva na različita računala moguće je izvoditi određene zadatke paralelno te s time postići veću učinkovitost sustava [6].

Na slici 3.3. možemo vidjeti primjer rasporeda razina za neki projekt, odjel i poduzeće. Vidimo da kod projekta imamo jednu bazu podataka, jedan sustav upravljanja podatcima, jedne alate kao i korisničko sučelje. Kod pojedinih odjela možemo imati više korisničkih sučelja, dok na razini poduzeća imamo više baza podataka, sustava za njihovo upravljanje, alata i korisničkih sučelja.



Slika 3.3. Raspored slojeva (razina) za projekt, odjel i poduzeće [6]

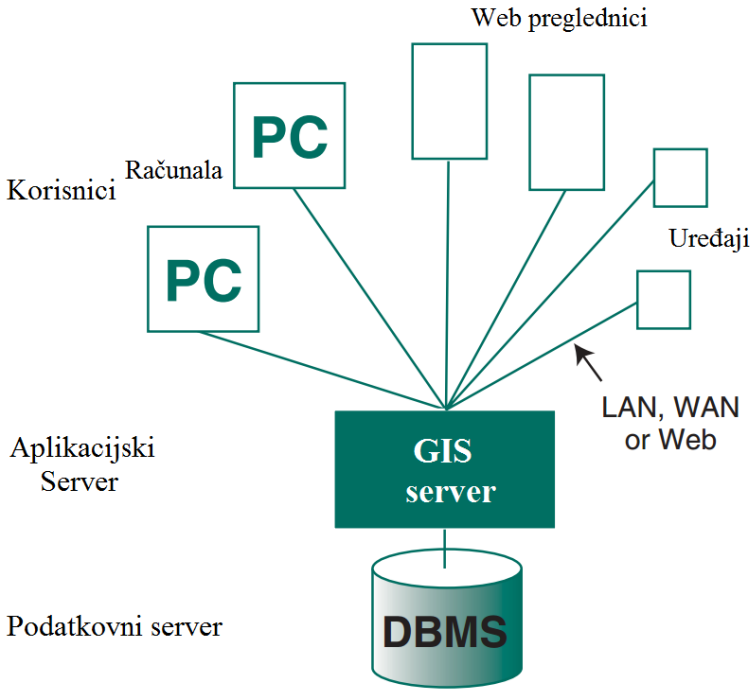
Postoje četiri vrste arhitektura računalnih sustava koje se najčešće koriste za GIS: *desktop*, klijent-poslužitelj, centralizirana *desktop* i centralizirana server. Kod najjednostavnijih *desktop* konfiguracija, kao što su geografski informacijski sustavi korišteni od strane jednog korisnika za određeni projekt, sve tri razine su najčešće instalirane na jednom računalu u obliku GIS *software-a* (slika 3.4. a). Varijacija ovakve konfiguracije može biti takva da su datoteke podataka smještene na centralnom podatkovnom serveru, no funkcije toga servera su i dalje dio GIS-a na računalu (slika 3.4. b) [6].



Slika 3.4. Arhitektura desktop GIS software-a [6]

U većim i naprednijim radnim grupama tri razine GIS-a mogu biti instalirane na više računala kako bi se unaprijedila fleksibilnost i učinak. Kod ovakve vrste konfiguracije, korisnik u pojedinom odjelu i dalje koristi *desktop* GIS grafičko korisničko sučelje na svome računalu, koje također sadrži svu poslovnu logiku, no *software* za upravljanje bazama podataka i baza podataka se nalaze na drugom računalu. Računala su spojena preko mreže, te na taj način razmjenjuju podatke. Ovakva se računalna arhitektura obično naziva klijent-poslužitelj, zbog toga što klijent od poslužitelja zahtjeva podatke ili usluge obrade. Nakon zaprimanja zahtjeva poslužitelj odrađuje posao kako bi zadovoljio zahtjeve klijenta. Podatkovni poslužitelj ima sposobnost obrade podataka, u mogućnosti je ispitati i obraditi podatke te dio baze podataka prikazati klijentu. Klijent i poslužitelj mogu komunicirati preko LAN-a (*Local area network*), WAN-a (*Wide area network*) i interneta. Zbog velike količine podataka koja se mora prenositi prilikom komunikacije između klijenta i poslužitelja, najčešće se koristi local area network (LAN) [6].

Desktop i klijent-poslužitelj konfiguracije imaju značajnu količinu funkcija na desktopu. Nasuprot tome kod centralizirane *desktop* konfiguracije grafičko korisničko sučelje i poslovna logika smješteni su na središnjem serveru, koji se naziva aplikacijski ili server srednje razine. *Software-ski* dodatak, također instaliran na aplikacijski server omogućuju korisnicima koji koriste udaljene uređaje da pristupe GIS *software-u* putem LAN-a ili WAN-a. Ovaj software omogućuje korisniku jednak pristup GIS-u kao da je on instaliran na njegovo računalo. Za upravljanje podatcima koristi se podatkovni server (DBMS). Ovakva konfiguracija koristi se u velikim odjelima i poduzećima koji zahtjevaju napredne mogućnosti kao što su napredno uređivanje, mapiranje i analiza. Najčešća verzija centralizirane *desktop* konfiguracije ima poslovnu logiku u obliku stvarnog serverskog sustava i pokreće je računalo srednjeg sloja. Ovakva konfiguracija vidljiva je na slici 3.5. [6].



Slika 3.5. Konfiguracija sa centraliziranim GIS-om [6]

U ovakoj konfiguraciji klijenti, *web* preglednici i uređaji posebne namjene sa serverom srednjeg sloja komuniciraju preko mreže (LAN, WAN, Internet). U slučaju korisnika koji imaju samo prezentacijski sloj, odnosno korisničko sučelje (*thin client*), prezentacijski sloj pokrenut je na serveru (iako se tehnički prikazuje na desktopu korisnika). Poslužitelji mogu biti spojeni preko *local area network-a*, no sve više se koristi internet kao veza za spajanje široko distribuiranih poslužitelja. Ovakav pristup je uobičajen za GIS u nekom poduzeću. GIS u velikim poduzećima može sadržavati desetke poslužitelja i čak stotine, pa i tisuće klijenata koji mogu biti široko distribuirani u geografskom smislu [6].

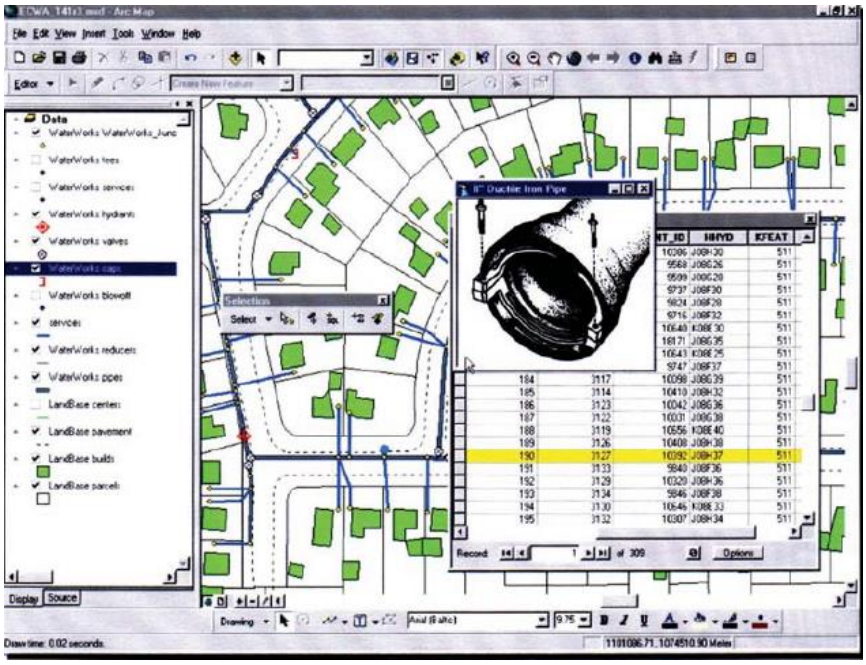
3.3. Vrste GIS SOFTWARE-a

Glavne karakteristike GIS *software-a* su analitičke funkcije koje pružaju nove geografske informacije koristeći postojeće prostorne i atributne podatke. GIS je računalni sustav koji pruža četiri skupa mogućnosti za obradu geografskih podataka, a to su: unos, upravljanje podacima (pohranjivanje i korištenje pohranjenih podataka), manipulacije i analize, ta izvoz informacija [5].

Više od stotinu komercijalnih *software-a* imaju mogućnosti mapiranja, te se može reći da su oni geografski informacijski sustavi. Proizvođači navode četiri osnovna tipa GIS software-a koji dominiraju tržištem, a to su: *desktop*, poslužitelj, razvojni GIS i prijenosni GIS [6].

Od sredine devedesetih godina desktop GIS je najčešće korišteni GIS software. Desktop GIS se razvio i opstao zavaljujući osobnim računalima i *Windows* operacijskom sustavu. U početku su glavni proizvođači radnu stanicu GIS *software-a* koji nije bio namjenjen upotrebi na osobnim računalima prenosili na osobno računalo, no kasnije su ponovno razvili *software* posebno za upotrebu na osobnom računalu. GIS *software* omogućuju alate koji poboljšavaju produktivnost za široku paletu korisnika te za razna poslovna i društvena područja. Računala su vrlo dostupna, relativno jeftina te nude razne alate orijentirane korisniku uključujući baze podataka, obradu teksta i proračunske tablice. *Desktop* GIS uključuje od jednostavnih preglednika (kao što su: *ESRI, ArcReader, Intergraph GeoMedia Viewer* itd.) do desktop mapiranja i sustava GIS *software-a* (kao što su: *Autodesk Map 3D, ESRI ArcView, GE Spatial Inteligence* itd.) i na kraju vrhunski, potpuno opremljeni, profesionalni sustavi za analizu i uređivanje (kao što su: *ESRI ArcInfo, Intergraph GeoMedia Professional i GE Energy Smallworld GIS*) [6].

Na slici 3.7. prikazana je primjena *Arc Map-a* za upravljanje vodovodnom infrastrukturom. Prema slici je vidljivo da software prikazuje prostorne podatke, dok su strukturni podatci pohranjeni u *excel* tablici. Dakle brza i jednostavna pretraga strukturnih podataka nije moguća u klasičnim geografskim informacijskim sustavima poput *Arc Map-a*.



Slika 3.6. Primjena *Arc Map-a* za upravljanje vodovodnom infrastrukturom

U kasnim devedesetima brojni proizvođači objavljuju besplatne GIS preglednike koji imaju mogućost prikazivanja popularnih formata. Danas se GIS preglednik razvio u značajni informacijski proizvod. Razlog razvoja ovakvih proizvoda je uspostavljanje tržišnog udjela kao i standardiziranje terminologije i formata podataka. Korisnici GIS-a najčešće rade sa preglednicima u kombinaciji sa sofisticiranim GIS *software-ima*. GIS preglednici imaju ograničene mogućnosti: prikazivanje, upiti i jednostavno mapiranje. Ne podržavaju uređivanje, sofisticirane analize ili prilagodbe. Većina uspješnih sustava je prihvatila *Microsoft-ove* standarde. Današnje korištenje GIS-a se većinom svodi na upotrebu podataka, a manje na kreiranje podataka i korištenje naprednih alata koji omogućuju mapiranje [6].

Korisnici na GIS software i desktop mapiranje gledaju kao na jednostavan alat koji im omogućuju da redovne poslove obavljaju brže, jednostavnije i jeftinije. Korisnici GIS-a rade poslove vezane za: planiranje, inženjering, poučavanje, marketing te druga slična zanimanja. Cijene GIS *software* kreću se od oko tisuću do dvije tisuće dolara. Profesinalni *software* su u potpunosti opremeljeni što uključuje prikupljanje i uređivanje podataka, administraciju baza podataka, napredno geoprocesiranje i analizu, kao i druge alate. Profesionalni sustav je nadmoćan u odnosu na ostale sustave. Profesionalne GIS sustave koriste tehnički pismeni tzv. GIS profesionalci. Najčešće imaju napredni stupanj obrazovanja vezano za GIS. Profesionalni

GIS je značajno skuplji od jednostavnih GIS software, te se cijena takvog *software* kreće od sedam tisuća pa sve do dvadeset tisuća dolara [6].

Krajem devedesetih i početkom dvije tisućitih godina domnirala je arhitektura *desktop* GIS-a koji je pokretan na stolnim računalima. Idućih desetak godina ipak dominaciju preuzima server GIS. Server GIS je GIS koji se nalazi i pokreće na računalu poslužitelja (serveru), te izvršava zahtjeve postavljene od strane umreženih klijenata, odnosno korisnika. Server GIS ima najveću bazu korisnika i najniže troškove po korisniku. Potaknuti napretkom u *hardware-u* i povezivanju servera, te širokoj dostupnosti interneta i sve većim zahtjevima za pristup geografskim informacijama, proizvođači su vrlo brzo prihvatili proizvoditi *software-e* koji se temelje na klijent poslužitelj komunikaciji. Primjeri takvih software-a uključuju Autodesk MapGuide, ESRI ArcGis Server, GE Spatial Application Server, Intergraph GeoMedia Webmap i MapInfo MapXtreme. Cijene ovakvih GIS proizvoda kreću se od pet tisuća do dvadeset i pet tisuća dolara, za male i srednje sustave [6].

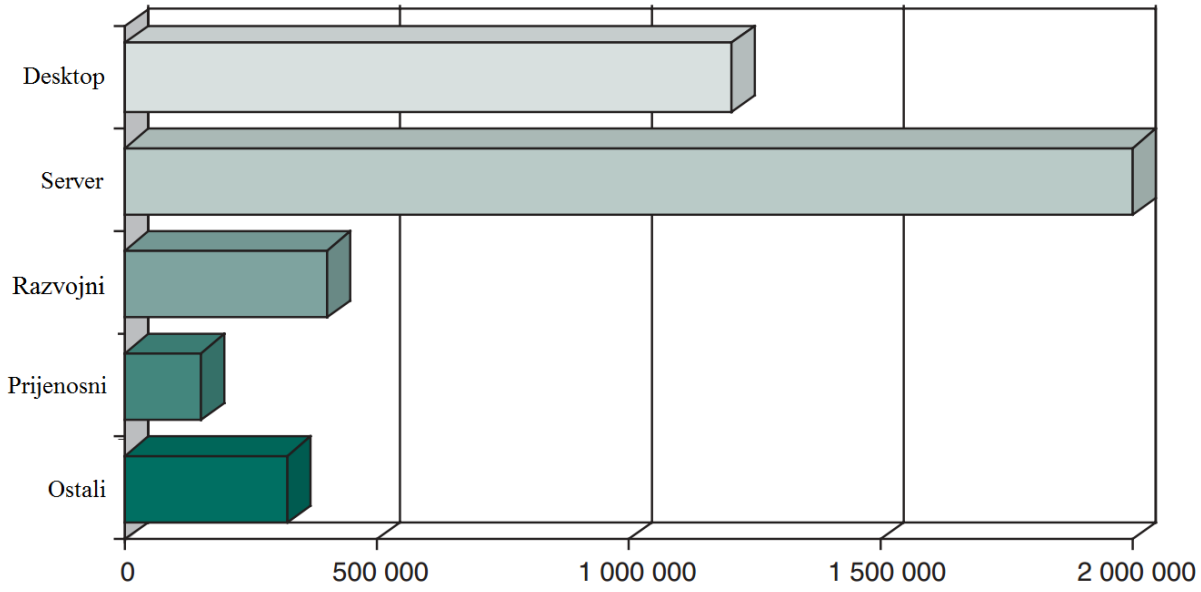
U početku takvi proizvodi su bili nadogradnje ili priključci *desktop* GIS-u, no druga generacija sustava je izgrađena s arhitekturom koja podržava veći broj korisnika, te im omogućuje da rade bez nadzora i obrađuju zahtjeve umreženih korisnika. Ovakvi *software-ski* sustavi u početku su se fokusirali na aplikacije za prikazivanje i upite, čineći jednostavne stvari još jednostavnijima i isplativijima. Napredne aplikacije postaju sve dostupnije kako se povećava broj korisnika te kako napreduje tehnologija. Danas se rutinski izvode operacije kao što su izrada karata, izrada putokaza s uputama i prikladne analize [6].

S razvojem GIS software-a, brojni proizvođači razvili su komponente GIS software-a namijenjene isključivo potrebama programera. To su zapravo alati namijenjeni programerima kako bi oni bili u mogućnosti izraditi GIS aplikaciju za posebnu namjenu. Ovakvi alati su od velike koristi programerima jer im omogućuju veliku prilagodbu i optimizaciju aplikacija koje mogu biti samostalne ili dio nekog software-skog paketa. Obično GIS paketi komponenti nude snažne mogućnosti kada su u pitanju alati za prikazivanje i upite, dok su ograničeni kada je u pitanju uređivanje i analiza. Dakle možemo zaključiti da su razvojni geografski informacijski sustavi skupina komponenti namijenjenih programerima kako bi izradili fokusirane, odnosno *software* posebne namjene [6].

Budući da su u zadnjih nekoliko godina uređaji sve manji, a jednako snažni kao i računala, otvorila se mogućnost razvoja GIS *software-a* za mobilne i ostale prijenosne uređaje. Razvoj jeftinih i jednostavnih tehnologija za pozicioniranje kao što je GPS, te bežično umrežavanje

(*wireless*) dodatno su potaknuli ovo tržište. Uređaji poput mobitela danas imaju mogućnosti jednake, pa često i veće u odnosu na računalni *desktop* GIS. Prijenosni uređaji imaju mogućnost prikazivanja, te slanja upita kao i mogućnosti jednostavnijih analiza. Unatoč kompaktnoj veličini pametni telefoni mogu s lakoćom koristiti GIS sustave. U tome im svakako olakšava njihova velika memorija, te mogućnost bežičnog povezivanja [6].

U ovom poglavlju navedene su različite vrste GIS *software-a*. Ukratko su opisane četiri osnovna *software-a*, odnosno četiri najzastupljenija *software-a*. Na slici 3.7. prikazana je zastupljenost pojedine vrste GIS *software-a*



Slika 3.7. Grafički prikaz broja korisnika za pojedine GIS *software* [6]

3.4. GIS u elektrodistribuciji

Autori u literaturi [7] navode: „Distribucija električne energije do kupaca obavlja se elektroenergetskom mrežom koja je po broju elemenata i njihovoj prostornoj rasprostranjenosti jedan od najsloženijih tehničkih sustava. Podaci o elementima elektroenergetske mreže, o njihovim međusobnim odnosima, informacije o pogonskom stanju mreže te priključak kupaca na mrežu samo su dio velike količine informacija koje su potrebne distribucijskom poduzeću. Praćenje tih podataka je nezamislivo bez korištenja baza podataka u kojima se pohranjuje informacija o svakom elementu mreže ili o kupcu. Cijeli postupak je još lakši ako se za to koristi prostorna baza podataka - geografski informacijski sustav (GIS).“

Prema literaturi [8]: Geografski informacijski sustav (GIS) u distributivnoj mreži ODS-a ima nezamjenjivu ulogu, a u svrhu kvalitetnog gospodarenja električnom energijom. Gotovo svi procesi i aktivnosti distribucije električne energije su vezani za prostor, a poznavanje prostora i objekata u prostoru (građevinski, elektroenergetski, prometni...) je od neprocjenjive važnosti za ovu djelatnost. Zbog kompleksnosti problematike GIS-a, kao i nužnosti distribucijskih područja korištenjem takvim tehnologijama, nužno je kvalitetno urediti odnose između prostora i elektroenergetskih objekata, postrojenja, mreže i sl. Zbog istovjetnih aktivnosti distribucije električne energije na cijelom području ODS-a nužno je pronaći zajednička rješenja unutar GIS-a (planiranje, izgradnja i gospodarenje i sl.).“

Također autori u literaturi [8] navode: „U sveopćoj informatizaciji i načinu poimanja stvari GIS se nameće kao nezamjenjiva karika u poimanju prostora i zakonitosti koji se u tom prostoru događaju. Kako je djelatnost distribucije električne energije neupitno vezana za prostor i objekte u tom prostoru, GIS ima zadatak da nam što bolje definira pravila koja vladaju u tom prostoru. Izvori (proizvodnja), prijenos kao i distribucija električne energije je isključivo vezana za prostor i mora biti međusobno povezana sa drugim subjektima u tom prostoru (vodotoci, prometnice, naselja, potrošači i sl.). Dosadašnji pristup prema poimanju prostora se pokazao nedostatan (karte, skice, matrice i sl.) te se GIS pokazao kao rješenje u savladavanju svakodnevnih potreba vezanih za prostor. GIS za potrebe kvalitetnog gospodarenja električnom energijom ima niz ciljeva:

- objedinjavanje višestrukih izvora prostornih podataka (grafički, numerički);
- objedinjavanje podataka o mreži koji se nalaze u raznim organizacijskim cjelinama;
- formiranje potpune, točne i sigurne baze podataka;
- definiranje logičkih i topoloških pravila (relacija) između pojedinih elemenata u mreži;
- povezivanje sa drugim temeljnim sustavima (SCADA, baza potrošača (CIS, BILING), itd.);
- razvoj, projektiranje, upravljanje, nadzor i održavanje elektrodistribucijske mreže;
- povezivanje sa drugim vanjskim sustavima (katastar, adresni sustav, lokalna uprava, itd.).“

Prema literaturi [7]: „Tradicionalni pristup GIS korisnika oslanja se na pohranjivanje prostornih podataka u datoteke uobičajenih formata kao što su npr. *AutoCAD DWG*, najčešće na razini odjela. Usprkos takvom jednostavnom pohranjivanju i korištenju prostornih podataka, ova metoda ne pruža performanse, sigurnost i raspoloživost podataka potrebnih za GIS kao potporu poslovnih ciljeva poduzeća. Zbog specifičnosti poslova pojedinih odjela, često se događa da svaki odjel kreira podatke za svoje potrebe. Bez jedinstvenog modela distribucijske mreže međusobna razmjena ili pristup podacima predstavlja veliki problem kod korištenja aplikacija. Ako i postoji podatkovna kompatibilnost između tih sustava, svaki od njih zahtijeva razvoj vlastitih aplikacija što na kraju vodi do neučinkovitog sustava. Iako se uvođenje GIS-a u poslovanje poduzeća najčešće promatra kao tehnologijski projekt rezerviran samo za specijaliste računarstva i informacijskih tehnologija, uspješni razvoj i primjena korporativnog GIS-a najviše ovisi o sudjelovanju i potpori menadžmenta te o kontrolnim mehanizmima provedbe projekta. Zbog toga se implementacija GIS-a treba prije svega promatrati kao kontinuirani inovativni proces koji povezuje tehnologiju, podatke, poslovne procese, ljudske resurse i zajedničko sudjelovanje svih zainteresiranih strana u tvrtki.“

4. EKSPERTNI SUSTAV

4.1. Umjetna inteligencija

Prvi korak u rješavanju problema je definiranje područja problema ili domene u kojoj se problem nalazi. Ova tvrdnja vrijedi u slučaju umjetne inteligencije, ali i u slučaju konvencionalnog programiranja. Jedna od definicija umjetne inteligencije kaže „umjetna inteligencija omogućava računalima da se ponašaju poput onih u filmovima“. Ovakva razmišljanja vežu se za sedamdesete godine prošlog stoljeća kada je cijelo područje umjetne inteligencije bilo u fazi istraživanja. Međutim danas postoji velik broj problema koji se rješavaju uz pomoć umjetne inteligencije [9].

U literaturi [10] navedeno je: „Iako je područje umjetne inteligencije relativno mlado područje, naslijedilo je mnoge ideje, stavove i tehnike iz drugih znanosti (humanističkih, prirodnih i kognitivnih znanosti). U današnje vrijeme, umjetna inteligencija spaja teorije zaključivanja i učenja (iz filozofije), formalnu logiku, teoriju vjerojatnosti, odlučivanja i računanje (iz matematike), mogućnost istraživanja ljudskog uma i znanstveni jezik u kojem se izražavaju nastale teorije (iz psihologije), teoriju strukture i značenje jezika (iz lingvistike) te alat s kojim pomoću umjetne inteligencije može stvoriti stvarnost preuzetu iz računalnih znanosti.“

Autorica u literaturi [10] navodi: „Da bi se govorilo o umjetnoj inteligenciji potrebno je definirati što je to inteligencija. Inteligencija dolazi od latinske riječi *Intelligere* što bi značilo razabrati, shvaćati, razumjevati. Ne postoji suglasnost oko definicije inteligencije. Većina definicija uključuje koncepte kao što su apstraktno rasuđivanje, razumijevanje, samosvijest, komunikacija, učenje, planiranje i rješavanje problema.“

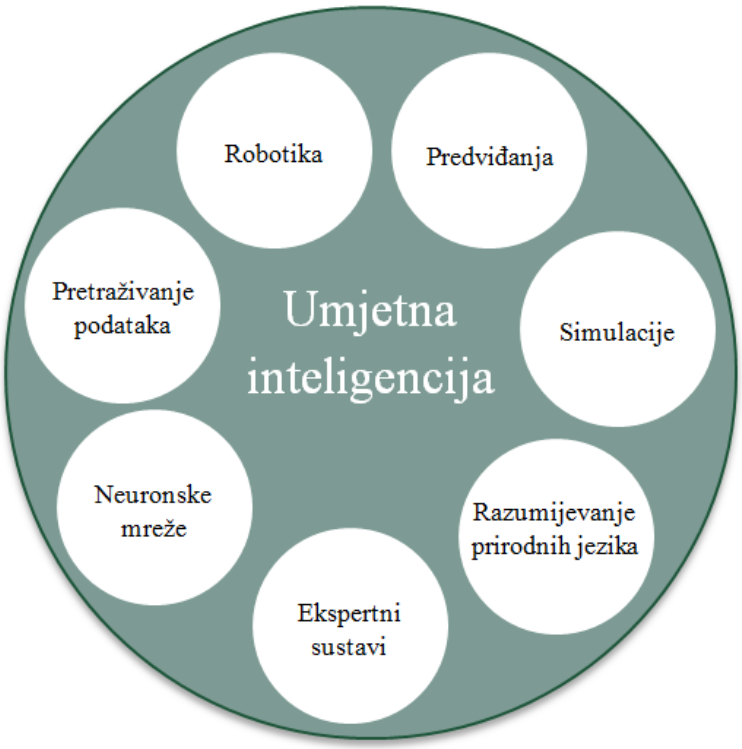
Definicije umjetne inteligencije navedene prema literaturi [10]: „Neke od definicija inteligencije su: svojstvo uspješnog snalaženja jedinke u novim situacijama (R. Pintner), sposobnost učenja prilagodbe na okolinu (Colvin), opća sposobnost asptraktnog zaključivanja pri rješavanju problema (Terman). Umjetna inteligencija je inteligentno ponašanje strojeva sa sposobnošću: zaključivanja, prikupljanja i upotrebe znanja, korištenja znanja i izmjenjivanja zamisli te postavljanje problema.“

Inteligentni sustav je svaki sustav koji pokazuje sljedeća svojstva [9]:

- Pokazuje prilagodljivo ciljano usmjereno ponašanje
- Uči na temelju iskustva
- Koristi velike količine znanja

- Pokazuje svojstva svjesnosti
- Komunicira s čovjekom prirodnim jezikom i govorom (kao što komuniciraju ljudi međusobno)
- Tolerira pogreške i nejasnoće u komunikaciji odgovara u stvarnom vremenu.

Opća rješenja za probleme kao što su prijevod određenog jezika, razumijevanje govora još uvijek nisu pronađena, no ipak umjetna inteligencija daje rješenja koja mogu biti od pomoći. Na primjer nije teško izgraditi jednostavan sustav za prevođenje, ako bi unos teksta ograničili na rečenice oblika imenica, glagol i objekt. Ekspertni sustavi surađuje sa *software-ima* koji sadrže baze podataka i proračunske tablice, te pruža korisničko sučelje jednostavno za korištenje [9]. Na slici 4.1 prikazana su neka od područja koja imaju korist te upotrebljavaju umjetnu inteligenciju.



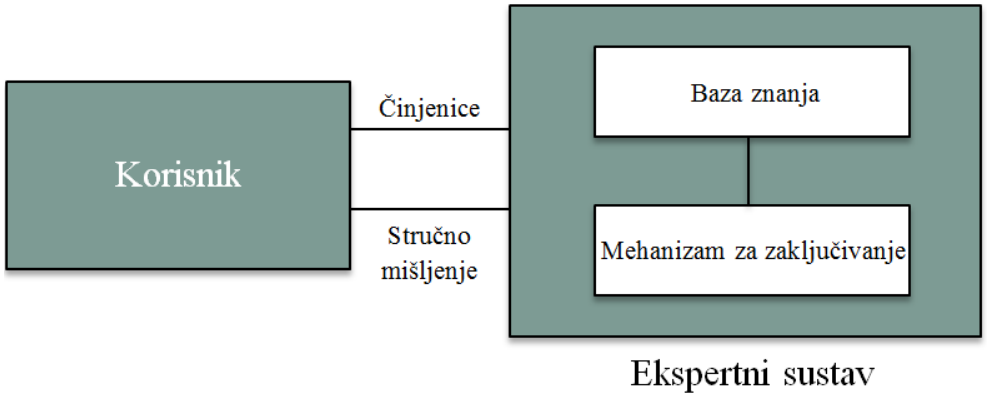
Slika 4.1. Područja u kojima se upotrebljava umjetna inteligencija [9]

Profesor Edward Feigenbaum sa Sveučilišta Stanford, jedan od ranih začetnika ekspertnih sustava, definirao je ekspertni sustav kao „inteligentan računalni program koji koristi znanje i postupke zaključivanja za probleme koji su dovoljno zahtjevni da iziskuju značajno znanja i sposobnost eksperta koji ih rješava“. To bi značilo da je ekspertni sustav, sustav koji oponaša eksperta kod donošenja odluka. Dakle ekspertni sustav se ponaša kao ekspert u svim segmentima. Ovakvi sustavi su puno snažniji od simulacija koje imaju mogućnost oponašanja samo određenih segmenata [9].

Iako još ne postoji opći sustav za rješavanje problema, ekspertni sustavi vrlo dobro funkcioniraju u svojim područjima. Dokaz uspješnosti sustava su brojne aplikacije u poslovanju, medicini, znanosti i inženjeringu, kao i brojne knjige, članci, konferencije i proizvodi posvećeni ekspertnom sustavu [9].

Ekspertni sustav je grana umjetne inteligencije, koji pomaže u donošenju odluka na razini ljudskih eksperata. Ljudski eksperti su osobe koje imaju velika znanja u nekom području odnosno kažemo da su eksperti za to područje. To znači da imaju znanje i posebne vještine u određenom području koje „obični“ ljudi nemaju. Eksperti mogu rješiti probleme koje drugi ljudi nisu u mogućnosti ili mogu rješiti probleme na efikasniji načni (ne nužno i jeftiniji). Kada je ekspertni sustav razvijen, u sedamdesetim godinama prošlog stoljeća, sadržavao je stručna znanja. Međutim, danas se pojam ekspertni sustav koristi za svaki sustav koji koristi tehnologiju ekspertnog sustava. Tehnologija ekspertnog sustava uključuje posebne jezike ekspertnog sustava, programe i *hardware* dizajniran za razvoj i realizaciju ekspertnih sustava. Znanje u ekspertnom sustavu može biti stručno ili znanje koje je generalno dostupno iz knjiga i časopisa [9].

Slika 4.2. prikazuje osnovni koncept ekspertnog sustava temeljenog na znanju. Korisnik daje činjenice ili druge informacije sustavu, dok sustav vraća stručno mišljenje ili stručni zaključak korisniku. Dakle pojednostavljeno možemo reći da se ekspertni sustav sastoji od dvije glavne komponente. Baza znanja sadrži znanje pomoću kojeg sustav za zaključivanje donosi zaključke. Ti zaključci su odgovor ekspertnog sustava na korisničke upite [9].



Slika 4.2. Osnovni koncept ekspertnog sustava [9]

Korisni sustavi temeljeni na znanju dizajnirani su kao inteligentna pomoć pri odlučivanju ljudskim ekspertima. Ovi sustavi bazirani su na tehnologiji ekspertnih sustava zbog prednosti u razvoju. Što se više znanja dodaje takvom sustavu, to se on više ponaša kao ekspert. Ovakva pomoć može pomoći stručnjaku u rješavanju problema, to jest može ubrzati postupak pronalaženja rješenja i na taj način uštedjeti vrijeme ljudskom ekspertu. Još jedna primjena umjetne inteligencije su inteligentni instruktori ili učitelji. Za razliku od starih sustava računalnih instruktora, novi sustavi pružaju instrukcije koje su osjetljive na kontekst [9].

Ekspertno znanje je fokusirano na probleme u jednoj domeni. Domena problema je posebno područje kao što je medicina, financije, znanost ili inženjering. Ekspert se u svojoj domeni snalazi jako dobro, dok je za druge domene u većini slučajeva laik. Ekspertni sustavi su također rađeni poput ljudskih eksperata, dakle specijalizirani su za određenu domenu. Sposobnost rješavanja problema iz jedne domene ne preslikava se na neku drugu domenu. Od stručnjaka za šah se ne očekuje da bude stručnjak u medicini [9].



Slika 4.3 Odnos domene znanja i domene problema [9]

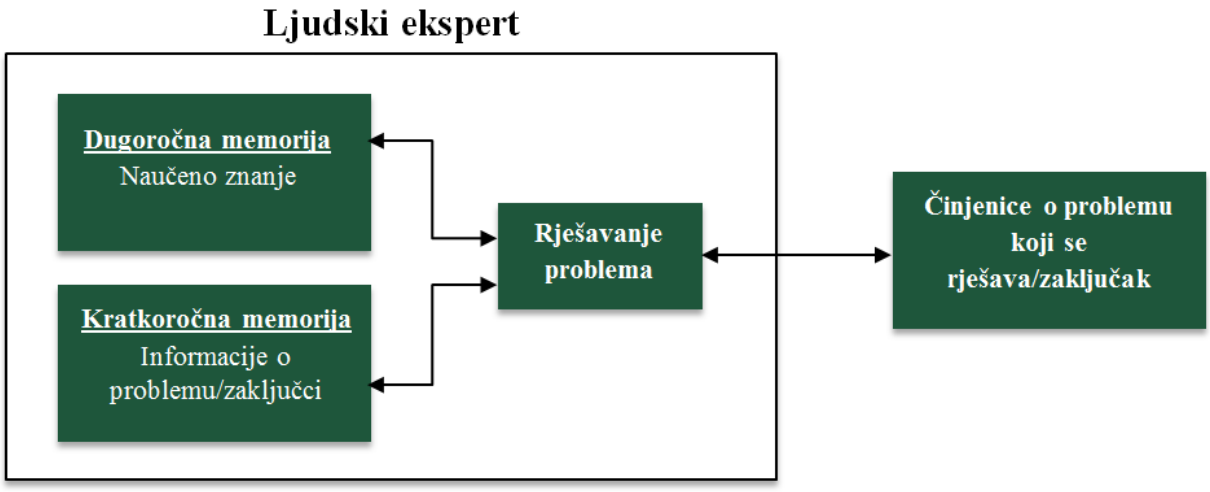
Na slici 4.3. ilustriran je odnos domene problema i domene znanja. Primjećujemo da se cijela domena znanja nalazi unutar domene problema. Dio koji se nalazi oko domene znanja simbolizira područje problema za koje nemamo rješenja. Dakle domena problema je uvijek veća od domene znanja. Naprimjer ekspertni sustavi u medicini, ako uzmemo ekspertni sustav sa znanjem u području kirurgije, ne očekujemo od njega da ima znanje u području pedijatrije [9].

4.2. Struktura ekspertnog sustava

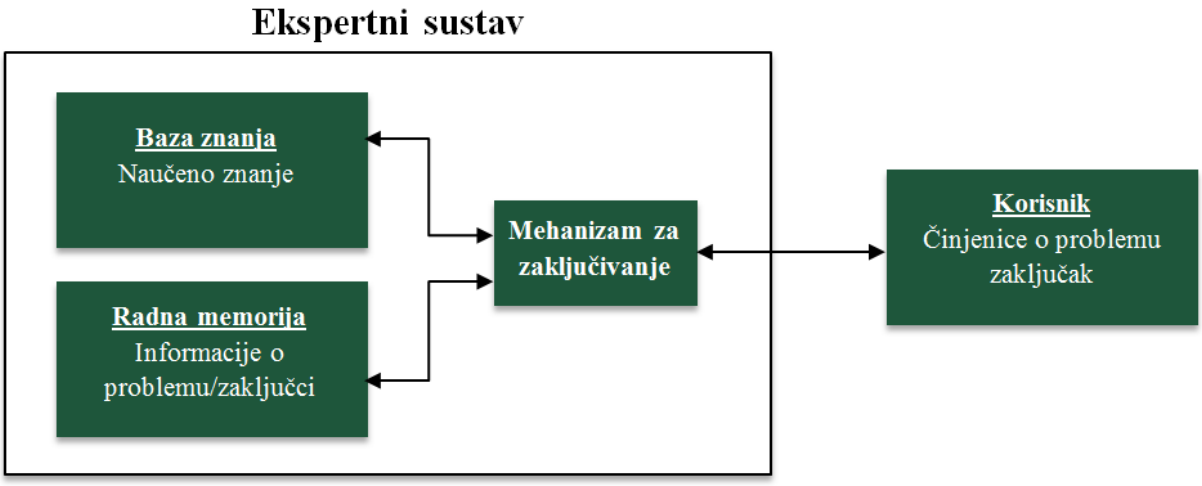
Potpoglavlje 4.2. nastalo je prijevodom te obradom prema literaturi J. Durkin, Expert Systems DESIGN AND DEVELOPMENT. Ekspertom smatramo osobu koja ima posebno znanje za

rješavanje problema u nekom području. U području ekspertnih sustava, to posebno znanje nazivamo naučenim znanjem (*domain knowledge*). Kod ljudskog eksperta naučeno znanje se nalazi u dugoročnoj memoriji. Prilikom pružanja savjeta, ekspert prvo saznaje činjenice o problemu i pohranjuje ih u kratkoročnu memorije, zatim rješava problem kombinirajući činjenice iz kratkoročne memorije i znanje iz dugoročne memorije. Koristeći ovaj proces ekspert donosi nove informacije o problemu i eventualno dolazi do zaključka i rješenja problema. Slika 4.4. prikazuje blok dijagram pristupa rješavanju problema od strane eksperta.

Kako bi smo ilustrirali proces, razmotrit ćemo problem otkrivanja kvara kod automobila. Pretpostavi se da postoji kvar na automobilu. Podrazumijeva se da se automobil odveze automehaničaru (ekspertu). Tijekom godina iskustva u popravljanju automobila, automehaničar je stekao veliko znanje u dugoročnoj memoriji koje mu pomaže prilikom otkrivanja kvara. Pretpostavimo se da automehaničaru kažemo da „automobil neće upaliti“. Automehaničar tu informaciju pohranjuje u kratkoročnu memoriju. Koristeći dobivenu informaciju, zajedno sa domenskim odnosno naučenim znanjem, automehaničar može zaključiti da je „problem u električnom sustavu“. Taj se zaključak pohranjuje u kratkoročnu memoriju te se nastavi razmišljati o rješenju problema. Dalje se može provesti ispitivanje akumulatora kako bi mehaničar mogao zaključiti „problem je slab akumulator“. Mehaničar ne samo da može riješiti problem nego može i objasniti kako je došao do zaključaka. Ekspertni sustav za rješenje problema koristi proces koji je vrlo sličan metodama kojima se koristi ekspert. Struktura koju koristi ekspertni sustav prikazana je na slici 4.5.



Slika 4.4. Pristup rješavanja problema od strane ljudskog eksperta [11]



Slika 4.5. Pristup rješavanja problema od strane ekspertnog sustava [11]

Ekspertni sustav naučeno znanje, koje ljudski ekspert ima u dogoročnoj memoriji, ima u bazi znanja. Pravila su jedan od tipičnih načina predstavljanja znanja u ekspertnom sustavu. Pravila imaju IF/THEN strukturu, gdje se logički povezuju informacije koje se nalaze u IF dijelu i druge informacije koje se nalaze u THEN dijelu. Na primjeru ćemo koristiti ova dva pravila za dijagnosticiranje kvara na automobilu:

RULE 1
IF Automobil neće upaliti
THEN Možda je problem u električnom sustavu
RULE 2
IF Automobil neće upaliti
AND Napon akumulatora je ispod 10 volti
THEN Problem je slab akumulator

Radna memorija sadrži činjenice o problemu koji je otkriven tokom interakcije. Radna memorija je model za kratkoročnu memoriju sa slike 4.3. Tijekom interakcije sa ekspertnim sustavom korisnik unosi informacije o problemu u radnu memoriju. Sustav koristi te činjenice kao i znanje iz baze podataka kako bi došao do novih činjenica. Zatim te nove činjenice šalje u radnu memoriju te se proces rješavanja problema nastavlja. Moguće je da sustav dođe do nekih zaključaka te njih također zapisuje u radnu memoriju. Radna memorija sadrži sve informacije o problemu, dakle one koje je unio korisnik kao i one do kojih je sustav došao. Mnogi ekspertni sustavi koriste podatke iz vanjske memorije kao što su vanjske baze podataka, tablice ili senzori. Sustav može učitati te informacije u radnu memoriju na početku sesije ili tokom procesa

interakcije prema potrebi. Sustav može odraditi cijelu sesiju koristeći isključivo te podatke ili ih može koristiti kao argumentiranje informacija koje je poslao korisniku.

Ekspertni sustav modelira proces ljudskog razmišljanja koristeći mehanizam za zaključivanje (*inference engine*). Mehanizam za zaključivanje proizvodi nove informacije koristeći činjenice koje se nalaze u radnoj memoriji i naučeno znanje koje se nalazi u bazi znanja. Mehanizam traži podatke koji se podudaraju s onime što je unio korisnik i znanjem sustava. Nakon što su pronađena podatci, nove činjenice dobivene šalju se u radnu memoriju te mehanizam ponovno traži nova podatke sve dok ne završi sesija, odnosno do rješenja problema. Za ilustraciju rada mehanizma za zaključivanje iskoristit ćemo pravila te pitanja sustava i odgovore korisnika koja smo spomenuli ranije:

KORAK 1
ESKPERTNI SUSTAV: Neće li automobil upaliti?
KORISNIK: Točno

Komentar: Korisnik je poslao ovu informaciju u radnu memoriju. Ekspertni sustav je prihvatio novu činjenicu i spremio ju u radnu memoriju:
IZJAVA KORISNIKA: Auto neće upaliti
ZAKLJUČAK SUSTAVA: Možda je problem u električnom sustavu

KORAK 2
EKSPERTNI SUSTAV: Je li napon akumulator manji od 10 volti?
KORISNIK: Točno
Komentar: Radna memorija sada sadrži nove činjenice i ekspertni sustav sprema nove činjenice u radnu memoriju
IZJAVA KORISNIKA: Napon akumulatora je manji od 10 volti
ZAKLJUČAK SUSTAVA: Problem je u neispravnom akumulatoru
Komentar: Sesija sada staje jer je problem riješen

Ovaj jednostavan primjer pokazuje svrhu odnosno na koji način se mehanizam za zaključivanje koristi u ekspertnom sustavu.

Zaštitni znak ekspertnih sustava je sposobnost da objasne svoje „razmišljanje“. Iako na slici 4.5. nije prikazan ekspertni sustav ima dodatak koji se naziva modul za objašnjenje. Modul za objašnjenje omogućuje ekspertnom sustavu da objasni korisniku zašto ga pita određena pitanja,

te kako je došao do zaključaka. Ovaj modul je prednost za korisnike, ali i za razvojne stručnjake. Pomaže razvojnim stručnjacima u otkrivanju eventualnih pogrešaka u znanju sustava.

Interakcija između ekspertnog sustava i korisnika provodi se simboličkim jezikom. Komunikacija je interaktivna te se odvija poput komunikacije između ljudi. Prilikom dizajniranja korisničkog sučelja velika pozornost se obraća da komunikacija bude što prilagođenija ljudima. Osnovni zahtjev za korisničko sučelje je mogućnost postavljanja pitanja. Kako bi se došlo do informacija mogućnost postavljanja pitanja je neizostavna. Također vrlo važno je da korisnik ima mogućnost pregleda te promjene informacija u radnoj memoriji. To je vrlo važno kod aplikacija u kojima bi korisnik mogao imati zahtjev za promjenom prethodnih pitanja odnosno odgovora. Korisničko sučelje mora biti dizajnirano tako da korisniku bude ugodno i jednostavno raditi.

4.3. Karakteristike ekspertnog sustava

Uobičajeni ekspertni sustav je osmišljen tako da ima sljedeće karakteristike [9]:

- Visoke performanse. Sustav mora biti u mogućnosti rješavati probleme na jednakoj ili čak višoj razini od ljudskog eksperta za određeno područje. To jest savjeti koje daje sustav moraju biti vrlo kvalitetni.
- Odgovarajuće vrijeme odziva. Sustav mora odrađivati posao u razumnom vremenu, to jest vrijeme potrebno sustavu da odradi određeni posao mora biti jednako ili kraće od vremena potrebnog ekspertu za isti posao. Ekspertni sustav kojem je potrebna godina dana za donošenje odluke je beskoristan, ako je za isto donošenje odluke ekspertu potrebno sat vremena. Vrijeme ima poseban značaj kod ekspertnih sustava koji rade u stvarnom vremenu, kada sustav mora dati odgovor u zadanom, što kraćem vremenu.
- Dobra pouzdanost. Ekspertni sustav mora biti pouzdan i ne smije biti sklon rušenjima u protivnom se neće koristiti.
- Razumljiv. Sustav bi trebao tokom rješavanja objašnjavati korak po korak kako bi postupak bio jasan korisniku. Sustav bi trebao moći objasniti način kako je došao do zaključaka baš poput ljudskog eksperta. To je puno korisnije nego da daje odgovore bez ikakvog objašnjenja. Ova značajka je vrlo važna iz nekoliko razloga.

Jedan od razloga je da imovina i ljudski životi mogu ovisiti o odgovorima sustava. Zbog mogućnosti da izazove veliku štetu sustav mora biti u mogućnosti objasniti svoje zaključke kao što to ekspert čini. Dakle modul za objašnjenje pomaže korisniku da prati te kontrolira

eventualne greške sustava. Drugi razlog je taj da prilikom razvoja određenog ekspertnog sustava možemo provjeriti dali je uneseno točno znanje u sustav i dali sustav to znanje koristi na ispravan način. To je vrlo važna prilikom kontrole ispravnog rada sustava, jer je lako moguće da je došlo do pogrešnog unosa znanja ili nesporazuma između ljudskog eksperta i inženjera zaduženog za znanje sustava. Ovisno o sustavu, modul za objašnjenje može davati jednostavna ili složena objašnjenja [9].

- Mogućnost promjena. Zbog velikih količina znanja koje se nalazi u ekspertnom sustavu, važno je da postoje učinkoviti mehanizmi za dodavanje, mijenjanje i brisanje znanja. Jedan od razloga zašto su ovakvi sustav dobro prihvaćeni je taj da se pravila mogu pohraniti u sustav na vrlo efikasan način [9].

Kao što je prikazano na slici 4.2. baza znanja i mehanizam za zaključivanje su razdvojeni moduli u ekspertnim sustavima. Odvajanje znanja sustava od njegove kontrole vrlo je važna značajka ekspertnih sustava. Ovo odvajanje razlikuje ekspertne sustave od uobičajenog programiranja. Konvencionalni računalni programi miješaju znanje programa sa upravljanjem znanja. Glavni nedostatak kod konvencionalnog programiranja je taj da promjena koda utječe i na znanje i na upravljanje. Također je teško pregledati kod i razumjeti koje znanje je upotrebljeno i na koji način. Razdvojenost znanja i upravljanja kod ekspertnih sustava olakšava modifikacije i održavanje sustava. Jednostavno se može locirati i mijenjati određeni dio znanja, ili dodavati novo znanje, također se mogu odraditi neophodna podešenja mehanizma za zaključivanje [11].

Vrlo važna značajka znanja koje se koristi u ekspertnim sustavima je činjenica da je u sustavu utjelovljeno znanje ljudskog eksperta. Znanje eksperata je znanje koje se pokušava snimiti i ugraditi u sustav. To uključuju naučeno znanje i vještine rješavanja problema. Stručno znanje je resurs kojim raspolaže nekolicina ljudi te ga uspješno koristi za rješavanje problema. To znanje ne mora nužno biti jedinstveno i genijalno, ali je specifično i vrlo korisno za ekspertni sustav. Ekspert je osoba koja ima vještine rješavanja problema na djelotvoran i učinkovit način. Doktor koji dijagnosticira bolesti, bankovni menadžer ili tehničar koji popravlja neki sustav mogu biti smatrani stručnjacima na njihovom području. Označavamo ih ekspertima kada pokazuju sposobnost razmišljanja koje je superiornije u odnosu na druge u njihovoj struci [11].

Većina eksperata je vješta u rješavanju problema koji su usko vezani za njihovo područje djelovanja, ali imaju ograničenu sposobnost izvan tog područja. Poput ljudskih eksperata i ekspertni sustavni su snažni na svom području, dok se izvan tog područja ne snalaze dobro.

Primjerice, ne bismo očekivali od ekspernog sustava dizajniranog za dijagnostiku automobila da bude učinkovit u financijkom planiranju [11].

Ekspertni sustav predstavlja znanje simbolički. Pomoću simbola možemo predstaviti različite vrste znanja kako što si činjenice, pojmovi ili pravila. Veliki dio ranijih radova vezanih uz umjetnu inteligenciji bilo je razvijanje programskih tehnika koje bi mogle učinkovito obrađivati simbole [11].

Prije početka projekta u ekspertnom sustavu, važno je utvrditi dali je problem uopće rješiv. Činjenica da svaki problem nije rješiv ekspertnim sustavom mogla bi iznenaditi nove korisnike koji misle da je umjetna inteligencija sposobna riješiti svaki problem. Ovakva razmišljanja kod osoba koje se upoznaju sa ekspertnim sustavima najčešće su posljedica predstavljanja umjetne inteligencije u znanstveno-fantastičnim filmovima. Stvarnost je ipak malo drugačija, ako ne postoji ekspert koji je u stanju rješiti određeni problem, vrlo su male šanse da će ga ekspertni sustav riještit. Ako je problematika nova ili se prebrzo mijenja postoji šansa da ne postoji ekspert koji može rješiti problem. Ekspertni sustavi nisu osmišljeni kako bi rješavali novu problematiku ili problematiku kod istraživanja. Oni se primjenjuju na problemima koji trenutno mogu biti rješeni od strane ljudskih eksperata [11].

Za ekspertne sustave možemo reći da su genijalni poput ljudskih eksperata, no i sustavi dijele jedan nedostatak sa ljudskim ekspertima, a to je da nisu nepogrješivi. Prilikom svakog savjetovanja sa ekspertima i ekspertnim sustavima svjesni smo činjenice da mogu pogriješiti, no svejedno vjerujemo u njihovu najbolju prosudbu [11].

4.4. Razvoj ekspertnog sustava

Potpoglavlje 4.4. nastalo je prijevodom te obradom prema literaturi J. Durkin, *Expert Systems DESIGN AND DEVELOPMENT*. Pojavom prvih računala, započelo je i razvijanje programa koji omogućuju brzo računanje, pristup informacijama ili modeliranje kompleksnih procesa. Iskustvom dobivenim izradom mnogih sustava i programa, programeri su razvili tehnike koje im olakšavaju izradu novih programa. Ekspertni sustav je na neki način dodatak računalnom programiranju. Za izradu ekspertnih sustava još uvijek ne postoje tehnike razvoja kao što je to slučaj kod konvencionalnog programiranja. Međutim, postoji nekoliko glavnih koraka za izradu ekspertnog sustava. Konvencionalno programiranje razlikuje se od programiranja ekspertnih sustava. Glavno obilježje konvencionalnog programiranja je slijedni postupak, dakle koraci se odrađuju redom jedan nakon drugoga. Izradu konvencionalnog programa obilježavaju tri glavna koraka: kreiranje algoritma, pisanje programskog koda te ispravljanje pogrešaka u programskom

kodu. Program je spreman za korištenje nakon što su svi koraci odrađeni. Razvoj konvencionalnog programa započinje nakon utvrđivanja zahtjeva koji su postavljeni pred program. Ovu fazu nazivamo fazom kreiranja algoritma, gdje programer prikuplja informacije kako bi uspio stvoriti sliku o kranjem izgledu programa. Nakon kreiranja algoritma započinje pisanje programskog koda. Tijekom pisanja koda programer najčešće radi sam. Zadatak ove faze programiranja je prijevod kreiranog algoritma u kod koji računalo razumije. Posljednja faza je ispravljanje pogrešaka u kodu. Programer testira program kako bi utvrdio dali program radi na željeni način. Pogreške otkrivene tijekom ove faze ispravljaju se promjenom izvornog koda. Ispravljanjem pogrešaka program bi trebao raditi kao što je zamišljeno na početku i time je projekt izrade programa završen.

Kod programiranja ekspertnog sustava cilj je stvoriti sustav koji će biti u mogućnosti steći znanje. Za razliku od konvencionalnog programiranja, razvoj ekspertnog sustava je iterativni proces. Programeri djelomično izrade sustav, testiraju ga te ispravljaju znanje unutar sustava. Ovaj proces se ponavlja gdje istovremeno rastu znanje u sustava i znanje, odnosno razumijevanje programera. Osnovne faze razvoja ekspertnog sustava su sljedeće:

- Procjena. Tijekom faze procjene istraživanja su usmjerena prema procjeni izvodljivosti i opravdanosti izrade programa. Istraživanja također ukazuju na glavne ciljeve projekta. U ovoj fazi definirane su značajke i opseg proces, kao i potrebni resursi.
- Stjecanje znanja. Cilj ove faze je stjecanje znanja o problemu koje će pomoći u daljnjem razvoju. Ovo znanje se odnosi na znanje o problemu kojeg treba riješiti, kao i na znanje o razvoju ekspertnog sustava.
- Razvoj. U fazi razvoja odnosno dizajniranja sustava traži se najbolji pristup da se znanje eksperta i strategija rješavanja problema predstave pomoću ekspertnog sustava. Tijekom faze razvoja definira su struktura i organizacija znanja.
- Testiranje. Faza testiranja nije poseban zadatak, nego je to postupak koji se obavlja tijekom trajanja cijelog procesa. Svaka komunikacija eksperta i sustava rezultira novim znanjem koje se pohranjuje u sustavu. Testiranjem se također otklanjaju pogreške u znanju sustava.
- Dokumentacija. Nakon završetka projekta važno je sve informacije dokumentirati. Dokumentirane informacije mogu biti od pomoći programerima, kao i korisnicima ekspertnog sustava.

- Održavanje. Nakon implementacije sustava u radnu okolinu, biti će potrebno sustav održavati. Korištenje ekspertnog sustava on raste i pohranjuje nova znanja. Dakle znanje u ekspertnim sustavima nije statično već neprestano raste. Također je ponekad potrebno osvježiti i nadograditi znanje kako bi zadovoljilo trenutne potrebe.

Glavni sudionici projekta vezanog za ekspertne sustave su: ekspert, programer te krajnji korisnik. Svaki od njih ima ključnu ulogu u razvoju ekspertnog sustava. Ekspert treba imati znanje u domeni za koju se sustav razvija. Također mora imati razvijene sposobnosti rješavanja problema kao i sposobnosti prenošenja znanja. Programer mora imati razvijene komunikacijske vještine, te mora znati predstaviti rješenje problema unutar *software-a*. Znanje eksperta mora prenjeti u znanje računalnog programa, odnosno ekspertnog sustava. Krajni korisnik treba pomoći prilikom definiranja karakteristika korisničkog sučelja. Također mora biti u mogućnosti pomoći u razvoju znanja sustava. Od korisnika se očekuje da svojim djelovanjem mijenja i dodaje znanje ekspertnom sustavu.

5. SUSTAV ZA POMOĆ PRI PROSTORNOM ODLUČIVANJU

5.1. Definicija sustava za pomoć pri prostornom odlučivanju

Sustavi poput *Google Maps-a* i *Map Quest-a* pokazali su važnost i vrijednost sustava za prostorno odlučivanje. No, koja je razlika između geografskog informacijskog sustava (GIS) i sustava za pomoć pri prostornom odlučivanju (SDSS), te kako su ova dva sustava općenito povezana? U proteklih 10 godina, prostorne aplikacije i aplikacije bazirane na lokacijama znatno su se proširile. Razlozi za njihovu širu upotrebu leže u činjenici da su pametni telefoni dostupni gotovo svima te se lako povezuju sa satelitskim navigacijskim sustavom (GPS) i internetom. Satelitski navigacijski sustav pruža informacije o lokaciji. Razne organizacije imaju mogućnost prikupljanja i korištenja prostornih podataka, dok sustav za pomoć pri prostornom odlučivanju osigurava pristup, te analizu podataka [12].

Portal Spatial Decision Support Knowledge na Sveučilištu Redlands navodi, pomoć pri prostornom odlučivanju je računalna ili informacijska pomoć za bolje donošenje odluka kod geografskih ili prostornih problema. Ovakav sustav pomaže pri razvoju, procjeni i odabiru prikladnih politika, planova, scenarija, intervencija ili strategija riješavnja problema [12].

Općenito je teško definirati jedinstvenu definiciji sustava za pomoć pri odlučivanju (DSS) kao i definiciju sustava za pomoć pri prostornom odlučivanju (SDSS). U širem smislu svaki sustav koji je pomoć pri donošenju odluka je sustav za pomoć pri odlučivanju (DSS). Razvoj sustava za pomoć pri odlučivanju je zapravo nadogradnja sustava za upravljanje informacijama (MIS), koji je razvijen u svrhu pomaganja pri donošenju odluka koristeći proceduralno znanje. MIS je kruti alat za pomoć pri odlučivanju. Vrlo malo pažnje se posvetilo problemima koji su fleksibilnije prirode odnosno nisu strukturirani, kao i interakciji između čovjeka i stroja. Ovakav alat nije prilagodljiv, a samim time nije ni učinkovit. S druge strane DSS omogućuje rješavanje strukturiranih, polustrukturiranih i nestrukturiranih problema. Tijekom godina pojavljivale su se razne karakterizacije DSS-a, no DSS generalno poznajemo kao fleksibilan, pouzdan i interaktivan računalni sustav za pomoć pri odlučivanju sa sučeljem prilagođenim čovjeku. Koristi sjedinjenje modela i velikih baza podataka za rješavanje velikih nestrukturiranih problema. Prve generacije DSS-a zapravo se nisu znatno razlikovale od MIS-a. Osim nešto fleksibilnije strukture i bolje prilagođenosti čovjeku, DSS se i dalje čvrsto oslanjao na modele za pomoć pri donošenju odluka. Vrlo malo pažnje se obraćalo na mogućnost korištenja umjetne inteligencije kako bi se poboljšalo zaključivanje te kako bi se unaprijedila komunikacija između donositelja odluka. Tek se posljednjih godina umjetna inteligencija prepoznala kao učinkovit

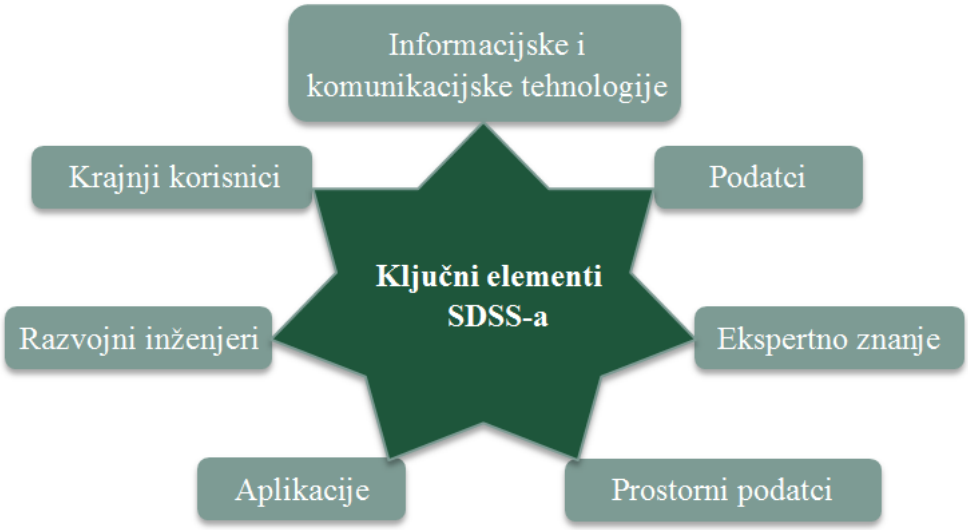
pristup za izgradnju DSS-a koji tako može iskoristiti strukturirano i nestrukturirano znanje za pomoć pri odlučivanju. Paralelno s razvojem MIS-a, izrađen je geografski informacijski sustav (GIS) koji daje prostorne informacije koje omogućuju lakše donošenje odluka. GIS je također mehanički sustav koji omogućuje pohranu, pronalaženje, analizu, te prikazivanje prostornih podataka. Njegova logička struktura i razina inteligencije nisu prikladne za rješavanje složenih prostornih problema, pogotovo onih sa neodređenom strukturom. Kako bi omogućio bolju podršku pri rješavanju problema, GIS bi trebao posjedovati mehanizme za upotrebu deklarativnog i proceduralnog znanja. Međutim današnji GIS je veliki sustav za obradu podataka te ne koristi različite vrste znanja. GIS ne može služiti kao središnji centar znanja, ali je vrlo važna komponenta SDSS-a. To jest, najprikladnije je ugraditi GIS u SDSS. Namjena SDSS je stvoriti okolinu za donošenje odluka u kojoj prostorne informacije i znanje mogu biti iskorišteni za rješavanje složenih prostornih problema. SDSS je vrlo sličan DSS-u osim što je kod SDSS-a naglasak na snimanju i obradi prostornih podataka kako bi se lakše rješavali prostorni problemi. Dakle SDSS bi trebao biti u mogućnosti [13]:

- snimati, unositi i pohranjivati prostorne i druge podatke iz različitih izvora;
- prikazivati složene prostorne strukture i odnose među prostornim podacima koji su prikladni za ispitivanje, pronalaženje, analizu i prikaz;
- omogućiti korištenje proceduralnog prostornog znanja (npr. matematičke modele, prostornu statistiku) i podataka;
- osigurati prilagodljivost za izmjene i poboljšanja;
- osigurati sučelje prilagođeno čovjeku;
- omogućiti različite vrste izlaznih podataka.

Većina današnjih sustava za pomoć pri prostornom odlučivanju temelji se na softwareu koji uključuje integraciju baza podataka i modela. Umjetna inteligencija, koja igra važnu ulogu u proučavanju ljudskog razmišljanja te koja bi pomogla u rješavanju problema koji su nestrukturirani, uglavnom je izostavljena. Umjetna inteligencija je od iznimne važnosti za SDSS kako bi se razvio u inteligentni sustav sa razumijevanjem i tehničkom sposobnošću razmišljanja [13].

5.2. Razvoj sustava za pomoć pri prostornom planiranju

Potpoglavlje 5.2. nastalo je prijevodom i obradom prema literaturi: R. Sugumaran, J. DeGroote, Spatial Decision Support Systems Principles and Practices. Kao što je ranije spomenuto, DSS pomaže u donošenju odluka koristeći tri glavne komponente: baze podataka, modele i korisničko sučelje. Sustav za pomoć pri prostornom odlučivanju je nadogradnja DSS-a koji koristi prostorne podatke za analizu i donošenje odluka. Iako istraživanja i aplikacije vezane u DSS imaju bogatu povijest, tek se nedavno počelo sa češćom implementacijom prostornih podataka i analiza, unatoč činjenici da je 80% podataka potrebnih za razne vladine i poslovne aktivnosti zapravo na neki način povezano sa prostornim podatcima. Ovakvo slabo korištenje prostornih podataka je posljedica nedostatka znanja i vještina vezanih za prostorne modele, prostorne analize i kartografiju. Uspješna upotreba tehnologija vezanih za prostorno odlučivanje tijekom sredine devedesetih godina ovog stoljeća zahtijevala je stručno znanje. Ovisila je o htjenju investiranja u software-sku i hardware-sku infrastrukturu kao i o ulaganju u potrebne ljudske resurse. Geografski informacijski sustav i s njime povezane tehnologije proučavale su se u geografskim odjelima sa poprilično jakim interesom za prostornim znanjem okolišnih, fizičkih i ekoloških znanosti. Ipak, do nedavno interes u poslovnom i ekonomskom svijetu je bio prilično slab, no to se počelo značajno mijenjati kada se je prepoznao marketinški potencijal prostornih podataka. Grafički prikaz pokretača koji su utjecali na razvoj SDSS, onakvog kakvog ga danas poznajemo prikazan je na slici 5.1.



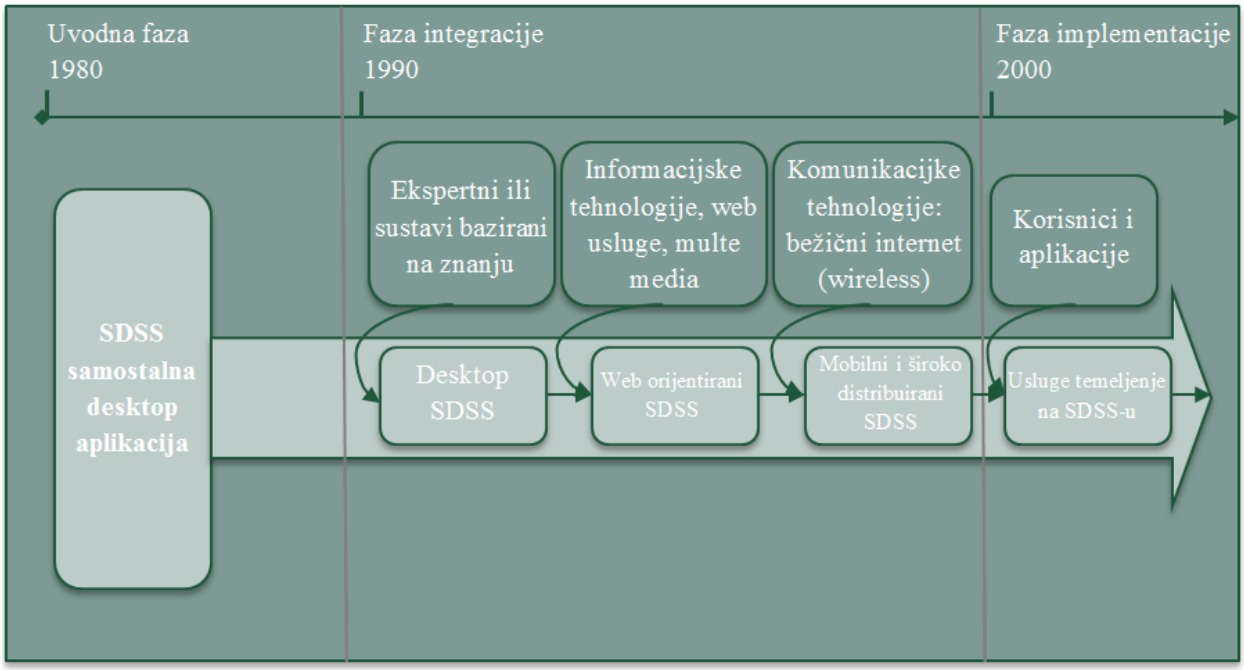
Slika 5.1. ključni čimbenici razvoja sustava za pomoć pri prostornom planiranju [1]

Mnoga svojstva karakteristična za GIS također su ključna u sustavima za pomoć pri prostornom odlučivanju (SDSS), kao na primjer sposobnost upravljanja prostornim podacima i mogućnost raznih analiza. Ipak geografski informacijski sustavi se ne smatraju sustavima za pomoć pri odlučivanju, a glavni razlog tome su nedostatak sposobnosti za analitičko modeliranje i nemogućnost prilagođavanja različitim scenarijima. Možemo istaknuti kako GIS općenito ne sadržava alate koji bi omogućili korisniku izbor i određivanje prioriteta u procjeni različitih kriterija i ciljeva. Ovi nedostatci ograničavaju učinkovitost GIS-a u rješavanju polustrukturiranih i nestrukturiranih prostornih problema. Predviđanje kretanja požara je primjer koji dobro prikazuje nedostatak modela. Funkcije GIS-a, kao što su upravljanje prostornim podacima i analiza, te mapiranje, ipak mogu biti iskorištene vezano za šumske požare. Međutim ako vatrogasci i druge nadležne službe za hitne slučajeve žele istražiti mogućnost korištenja resursa u različitim vremenskim uvjetima, moraju se osloniti na analitičko modeliranje. Takvi analitički modeli sadržavali bi matematičke algoritme kojima bi procesuirali informacije vezane za topografiju, vegetaciju, vremensku prognozu te niz drugih informacija kako bi se što bolje i preciznije predvidjelo ponašanje odnosno razvoj požara. GIS ne može djelovati izvan okvira, te ne bi mogao rješavati ovakve vrste zadataka. Razvojem software-a, algoritmi za modeliranje požara i alati za predviđanje scenarija koji koriste vremensku prognozu u stvarnom vremenu mogu biti ugrađeni u GIS ili povezani sa GIS-om tvoreći tako sustav za pomoć pri prostornom odlučivanju.

U posljednja četiri desetljeća, razvoju sustava za pomoć pri prostornom odlučivanju uvelike je doprinio značajan razvoj računalnih i komunikacijskih tehnologija, te njihovo povezivanje sa prostornim tehnologijama. Razvoj sustava za pomoć pri prostornom odlučivanju značio je integraciju analitičkih odnosno modela za donošenje odluka sa GIS-om tvoreći tako sustav koji ima mogućnost rješavanja prostornih problema. Povijest SDSS-a je vrlo slična povijesti GIS-a sa odmakom od nekoliko godina. Iako je koncept SDSS-a proizašao iz područja znanosti vezanih za odlučivanje, većina SDSS aplikacija temeljena je na geografskim informacijskim sustavima. Evoluciju SDSS-a možemo podijeliti u tri faze: uvod, integracija i implementacija.

Razvoj sustava za pomoć pri prostornom odlučivanju započinje u ranim sedamdesetima, polako se nastavio u osamdesetima, značajnije povećanje rasta dolazi u devedesetima i nastavlja sa rastom sve do danas. Razvoj SDSS popraćen je razvojem računala, većim brojem razvijenih aplikacija, razvojem snažnijih procesa, razvojem okoline prihvatljivije korisniku kao što je objektno orijentirano programiranje, te dostupnosti korištenja interneta. U drugoj polovici

devedesetih razvijene su prilagodljive, te jednostavnije desktop aplikacije. Prilagodljivost i moć u okruženju desktop aplikacija razvijala se i u dvije tisućitima te je vodila ka sve većem broju SDSS aplikacija. Veliki broj objava vezanih za SDSS u dvije tisućitima dogodio se, između ostalog, pod utjecajem povećanja web orijentiranih aplikacija. Na slici 5.2. prikazan je razvoj sustava za pomoć pri prostornom odlučivanju po fazama.

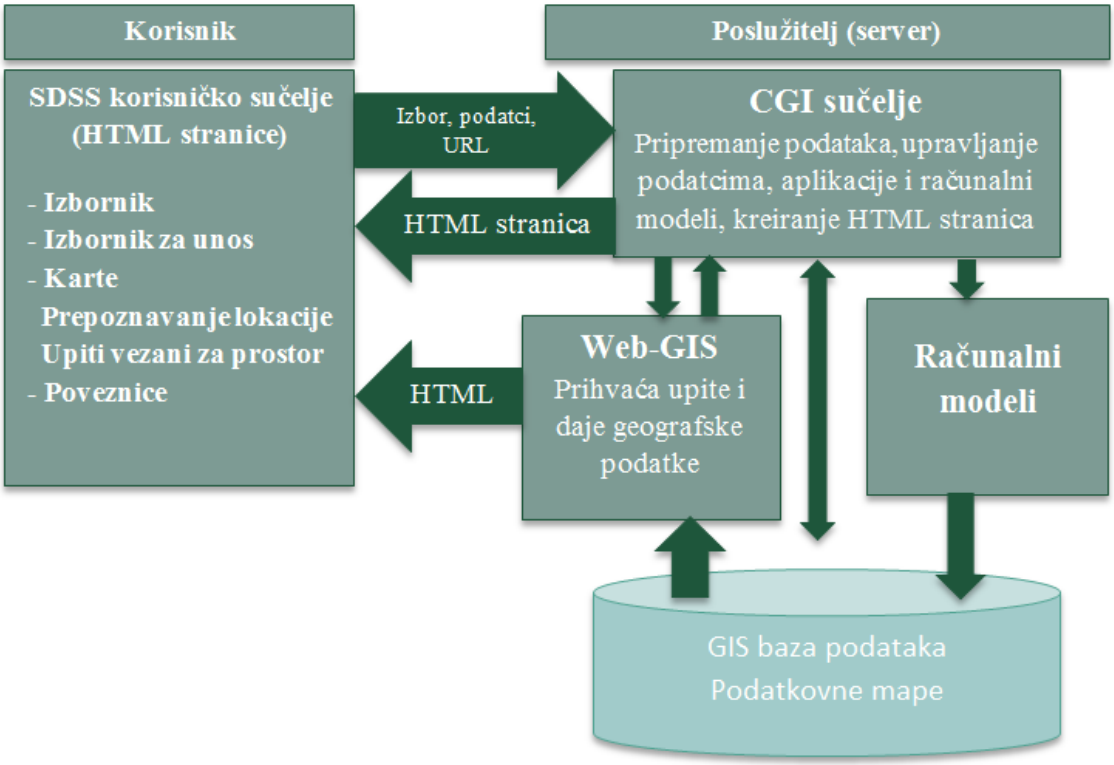


Slika 5.2. Razvoj SDSS-a po fazama [1]

5.3. Primjena sustava za pomoć pri prostornom odlučivanju

Prethodno potpoglavlje prikazuje evoluciju tehnologija i aplikacija vezanih za sustav za pomoć pri prostornom odlučivanju. Poseban naglasak je na velikom broju, te širokoj upotrebi SDSS aplikacija u zadnjih petnaest godina. SDSS aplikacije omogućavale su rješavanje različitih prostornih problema iz različitih domena, korištenjem raznih tehnologija. Cilj ovog poglavlja je pružiti pregled različitih tipova SDSS aplikacija i pružiti detaljan opis SDSS aplikacija iz različitih domena primjene. U poglavlju se naglašava široka primjena SDSS aplikacija. Poglavlje daje uvid menadžerima, ljudima zaduženim za planiranje i razvoj u mogućnosti primjene SDSS-a u različitim područjima. Pregled poglavlja kao i drugih sličnih baza podataka omogućuje istraživačima, menadžerima i implementatorima da se fokusiraju na specifične primjene SDSS u određenim domenama, kao što su geografska, tehnička ili znanstvena. Programeri koji razvijaju SDSS aplikacije imaju mogućnost istraživanja postojećih aplikacija koje im mogu biti od pomoći prilikom razvitka vlastite. Naime, mogu vidjeti koje tehnologije su korištene (GIS orijentirane, web orijentirane), razinu integracije i software koji su korišteni za razvijanje SDSS-a [14].

Web orijentiran DSS je računalni sustav koji pruža informacije za pomoć pri odlučivanju ili alate za pomoć pri odlučivanju koristeći neki od web preglednika kao što su Internet Explorer ili Netscape Navigator. Računalni poslužitelj kod kojeg se nalazi DSS aplikacije povezan je sa korisničkim računalom preko interneta pomoću TCP/IP protokola. U mnogim tvrtkama, web orijentirani DSS je sinonim za DSS koji na razini poduzeća spaja grupe upravitelja, te im pruža specijalizirano skladište podataka. Web orijentirani DSS može biti proširen na također web orijentirani SDSS, koji koristi web orijentirani GIS kao rješenje problema koristeći geografske podatke za upit, prikaz i analizu procesa. Iako web orijentirani SDSS može kombinirati više različitih komponenti, u suštini se sastoji od HTML korisničkog sučelja, programa internetskog sučelja, računalnih modela i geografskih baza podataka. Komponente web orijentiranog SDSS-a prikazane su na slici 5.3., koji se bazira na Common Gateway Interface (CGI) internetskoj komunikaciji [14].



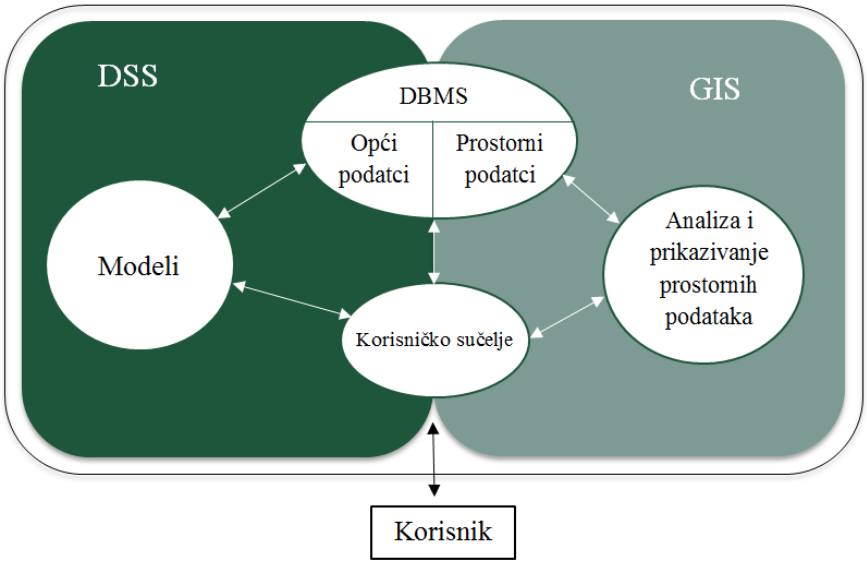
Slika 5.3. Shematski prikaz web orijentiranog SDSS-a baziranog na CGI internetskoj komunikaciji [14]

Kao što je prikazano na slici 5.3. web orijentirani SDSS koji koristi CGI ima HTML stranice kao korisničko sučelje, sučelje CGI aplikacija, računalni model, web orijentiranu GIS aplikaciju i geografske baze podataka i datoteke. Ovakav pristup rezultira kompliciranom serverskom stranom, dok je klijentska strana jednostavnija. To omogućava visoke performanse kod integracije podataka, upravljanja sustavom, brzine u komunikaciji i relativno jednostavnog preuzimanje HTML stranica pri korištenju poslužiteljskih platformi. Korisničko sučelje SDSS-a uključuje menije, grafički prikaz karti, kontrolne tipke i obrazac za unos. Ovakvo sučelje omogućuje odabir, unos podataka i prikazivanje karti, koristeći HTML oznake, Java umetke, Javascript i druge internetske protokole. Događanja na strani klijenta šalju se poslužitelju HTML protokolom, a poslovi koje klijent traži obavljaju se putem CGI-a ili nekog drugog internetskog sučelja. CGI sučelje obavlja komunikaciju uključujući primanje podataka, upravljanje datotekama na strani servera, pokretanje aplikacija uključujući računalne modele i ispisivanje rezultata u datoteke ili internetski preglednik klijenta, odnosno korisnika. CGI obavlja manipulacije GIS-ovim bazama podataka uključujući čitanje, ispitivanje, pripremanje slike za zahtjeve klijenata i standardno pripremanje HTML stranice. Računalni model obavlja računalne zadatke koristeći numeričke modele. Web orijentiranih SDSS-ovih razvojnih jezika i protokola ima u izobilju. Iako većina računalnih jezika može pisat CGI aplikacije, posebni jezici za razvoj

web aplikacija često se koriste zbog njihove učinkovitosti i funkcionalnosti. HTML, C, Practical Extraction i Report Language (PERL), Java i Hypertext Preprocessor (PHP) su najčešće korišteni za razvoj web aplikacija [14].

Sustavi računalne podrške kao što je SDSS pomažu prilikom rješavanja nestrukturiranih problema. Sustav za pomoć pri prostornom odlučivanju karakterizira širok spektar primjene, te primjena na različitim područjima. SDSS treba biti jednostavan za uporabu, omogućiti rješenja prezentiranjem niza alternativa, prilagodljiv kod upotrebe. Kako bi se ostvarili navedeni uvjeti postoje određene komponente koje SDSS treba sadržavati. Komponente koje treba posjedovati su: baze podataka, prostorne eksplicitne modele, korisničko sučelje, vizualizaciju i mogućnost izvješćivanja. Upravljanje i analiza podataka obično je usko vezana uz geografske informacijske sustave, a ti sustavi su osnovna komponenta SDSS-a. Također vrlo važna komponenta sustava za pomoć pri prostornom odlučivanju je ekspertni sustav [1].

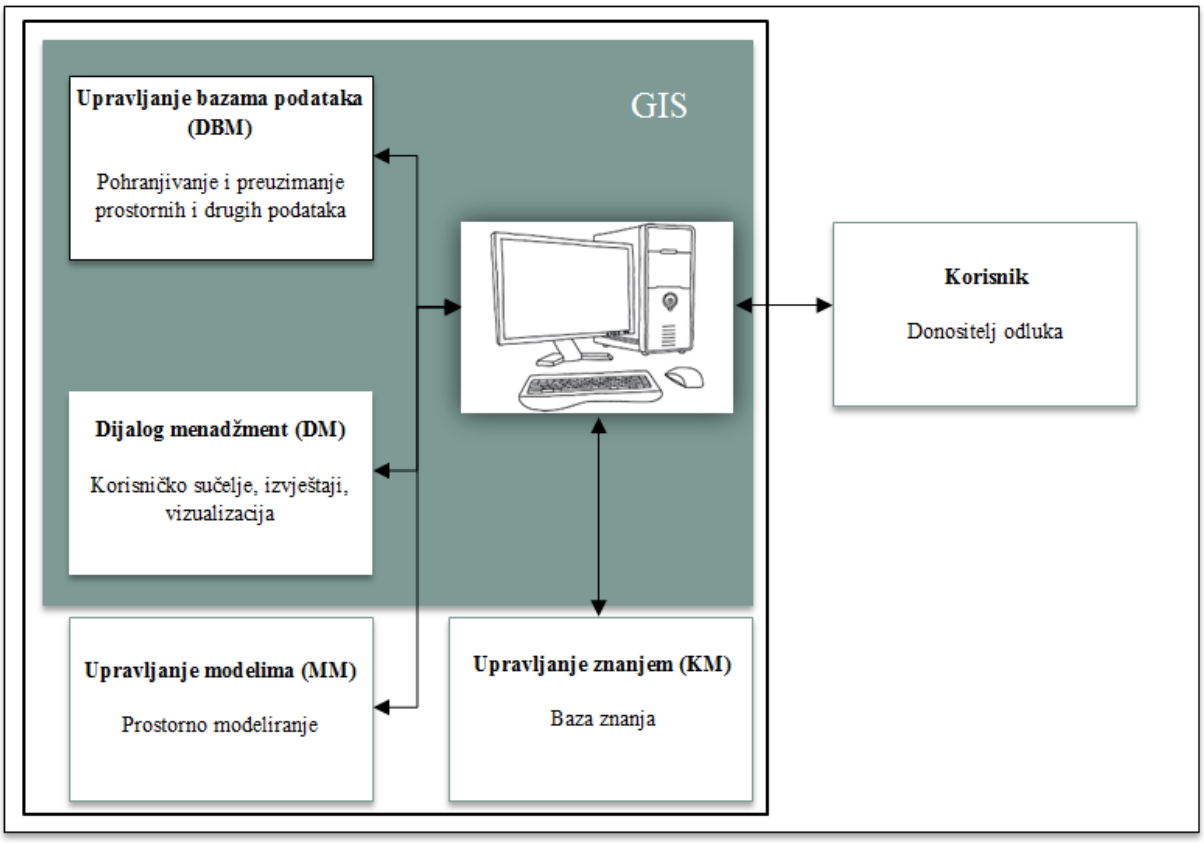
Kao što je ranije spomenuto možemo reći da se SDSS razvio iz ekspertnog sustava i geografskog informacijskog sustava. Slika 5.4. prikazuje kombinirane komponente GIS-a i ekspertnog sustava. Tradicionalni ekspertni sustav ima tri osnovne komponente: bazu podataka, bazu modela i korisničko sučelje. S druge strane GIS također možemo podijeliti na tri glavne komponente, a to su: baza podataka, korisničko sučelje i kreiranje prostornih podataka, analiza i prezentacija. Baza podataka kod ekspertnog sustava najčešće ne sadrži prostorne podatke, već se bavi prikupljanjem, pronalaženje, upravljanjem i analizom podataka koji nisu prostorni [1].



Slika 5.4. Tradicionalne komponente ekspertnog sustava (DSS) i GIS-a [1]

Ekspertni sustav obično ne podržava prezentaciju karti ili funkciju mapiranja, što je neophodno za donošenje prostornih odluka. S druge strane geografski informacijski sustav omogućava prikupljanje, pohranjivanje upravljanje prostornim i drugim podacima, kao i funkciju prikazivanja karti. Komponente baza podataka u oba sustava međusobno surađuju, te dostavljaju potrebne podatke jedna drugoj po potrebi. Osnovna komponenta omogućuje donositelju odluke pristup različitim modelima koji pomažu kod samog donošenja različitih odluka. Neki od primjera modela su statistički, matematički i višekriterijska procjena. Eksperni sustav izgrađen je tako da koristi različite tehnike modeliranja. GIS software koji sadrži prostorno-analitičke funkcije, ne posjeduje mogućnosti specifičnog analitičkog modeliranja. Osnovan komponenta modela radi sa podacima dostupnima u bazi podataka. Pristup bazi podataka može biti direktan ili korištenjem postupaka prebacivanja podataka. Korisnička sučelja GIS-a i ekspertnog sustava omogućuju lakšu interakciju između korisnika i računala. Ova komponenta igra vrlo važnu ulogu jer komplicirano i neobično sučelje može frustrirati korisnika. Stoga je vrlo važno da se uzme u obzir ova komponenta kao poveznica između korisnika i sustava. Na slici 5.4. je vidljivo kako GIS nema mogućnosti modeliranja, dok DSS ne podržava analizu prostornih podataka kao ni funkciju prikaza karti. Razvoj SDSS je omogućio korištenje komponenti iz GIS-a kao i iz ekspertnog sustava [1].

Prostorno odlučivanje uključuje identifikaciju problema, prikupljanje podataka, definiranje problema, uključujući ciljeve, pretpostavke i ograničenja, pronalaženje prikaldne procedure te pronalaženje optimalnog rješenja problema. Postoje tri osnovne komponente: baza podataka, model i korisničko sučelje. Ipak broj i točan opis komponenti SDSS u literaturi varira. Gao et al. (2004) govori o šest komponenti, a to su: podaci, modeli, rješenja, vizualizacija, scenariji i znanje. Ovdje navodimo četiri ključne komponente i jednu neobaveznu. Glavne komponente SDSS-a uključuju komponentu upravljanja bazama podataka (DBMC), komponenta upravljanja modelima (MMC), komponenta dijaloga (DMC) i komponenta dionika (SC) (Sika 5.5.). Komponenta znanja (KC) je česta, ali ne i esencijalna. Slika 5.5. daje pregled komponenti SDSS-a. GIS software često ispunjava ulogu upravljanja bazom podataka i upravljanja dijalogom. Ključnu ulogu u SDSS-u ima GIS software [1].



Slika 5.5. Komponente SDSS-a [1]

5.4. Budućnost SDSS-a

Potpoglavlje 5.4. nastalo je prijevodom i obradom prema literaturi: R. Sugumaran, J. DeGroote, Spatial Decision Support Systems Principles and Practices. SDSS i njemu slične tehnologije razvijaju se velikom brzinom, kao i većina drugih informacijskih sustava. Od devedesetih godina ovog stoljeća sve je više objava koje detaljno opisuju SDSS. Raspon primjene SDSS-a se proširio, te se i dalje nastavlja širiti. Očekuje se da će najveći rast upotrebe SDSS-a biti u onim disciplinama u kojima je tek nedavno otkrivena vrijednost korištenja SDSS-a. Poslovni svijet je u dvije tisućitima karakteriziran kao glavna disciplina za korištenje SDSS-a. Taj trend se nastavlja i dalje jer su usluge temeljenje na lokacijama postale uobičajene. U zadnje četiri godine većina objava vezanih za SDSS odnosile su se na javno zdravstvo. U zimi 2010.god. časopis ArcUser na naslovnici ima naslov: „Geomedicina: Mogu li geografske informacije čuvati vaše zdravlje?“ ističući tako interes javnog zdravstva za prostorne tehnologije. Ovakvi primjeri jasno ukazuju na rast razumijevanja te zapravo shvaćanje mogućnosti koje pružaju prostorne tehnologije, uključujući i SDSS, u raznim područjima. Tehnologija se razvija brzo, a vrijeme

velikih promjena u SDSS tehnologijama se trenutno događa. Web orijentirane SDSS aplikacije su postale vrlo česte te se očekuje nastavak njihovog rasta i u budućnosti.

Standardi web mapiranja (WMS) i GIS usluga (WFS) imaju i imati će vrlo važnu ulogu u razvoju SDSS-a. S obzirom na te standarde, valja istaknuti kako je većina prostornih podataka i dalje zadržana u specifičnim formatima. U budućem razvoju SDSS aplikacija veliku ulogu će imati podaci u stvarnom vremenu ili podaci vrlo blizu stvarno vremenskima. Podaci sa udaljenih područja odnosno senzora postaju sve dostupniji i sve češće će biti implementirani u SDSS. Primjer jedne takve aplikacije je web orijentirana aplikacije za prikazivanje udara munja u stvarnom vremenu. Aplikacija prikazuje trenutne podatke o udarima munja kao i podatke udara u zadnjih nekoliko sati. Poboljšanja u upravljanju prostorno vremenskim podacima preslikat će se na realnije modele unutar SDSS-a. Distribuirani GIS ili geoprostorne analitičke usluge u budućnosti će biti sve dostupnije. Te usluge će biti moguće koristiti desktop aplikacijama koje su povezane s mrežom, no najčešće će to biti korištenjem web orijentiranih aplikacija. Usluga može biti software-ska usluga koju korisnik plaća. Iako razvoj web orijantiranog SDSS-a raste još uvijek su desktop aplikacije češće.

6. REZULTATI

6.1. Sustav za pomoć pri prostornom odlučivanju u distribuciji (DeGIS)

Distribucijska mreža jedan je od najsloženijih sustava općenito, te je nezamislivo da takav sustav nema bazu u kojoj su pohranjeni podaci. Baza podataka u kojoj se nalaze podaci o mreži te podaci o prostoru u kojoj se mreža nalazi od ključnog su značenja za planiranje svih aktivnosti i procesa. U Hrvatskoj HEP-Operator distribucijskog sustava za prostorne podatke koristi DeGIS (Digital Energy GIS). Iako u nazivu stoji da je to geografski informacijski sustav, to je zapravo sustav za pomoć pri prostornom odlučivanju koji se sastoji od GIS-a i ekspertnog sustava.

Uvođenjem DeGIS-a u HEP-ODS rješen je problem paralelnog vođenja podataka. Dakle svi podatci su objedinjeni i svima dostupni. DeGIS je zamjenio sustave čija namjena nije manipulacija sa velikom količinom podataka. Najčešće se za mrežu i sheme koristio AutoCAD, te su podaci bili dostupni samo osobi koja ih je unjela. Danas unos, odnosno promjene u mreži su dostupne svima.

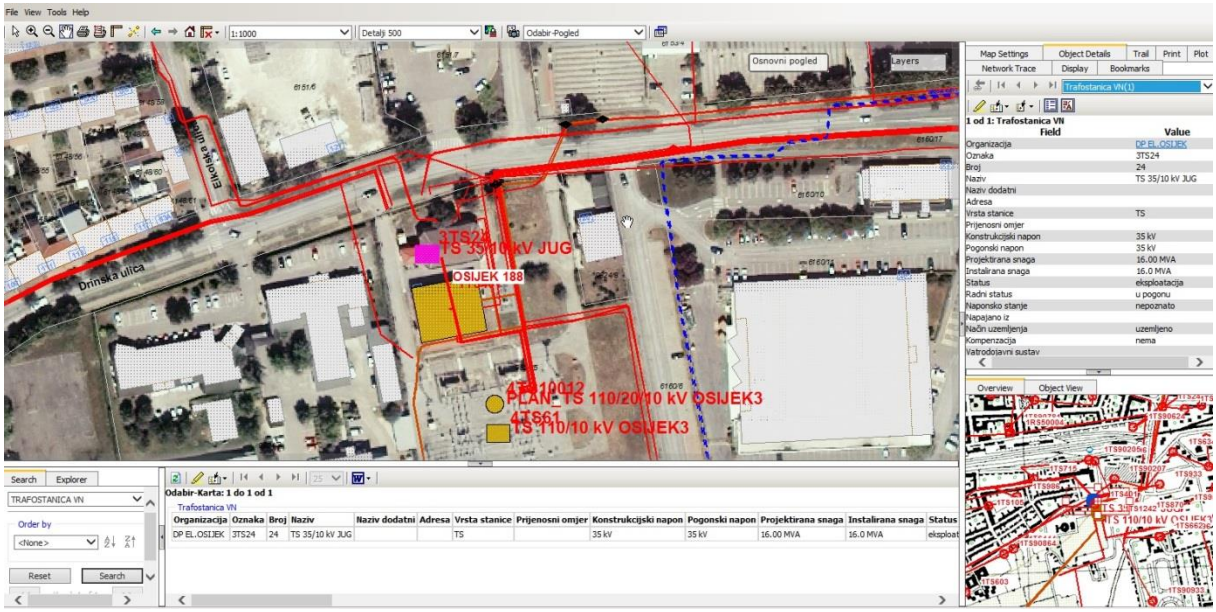
Odluka o korištenju DeGIS-a u HEP-ODS-u donesena je 2012. godine. Kako je potrebno unjeti ogromne količine podataka, tim za unos podataka i danas radi na tome, kao i na izmjeni odnosno ažuriranju postojećih informacija.

Održavanje, planiranje i razvoj, tehnička dokumentacija, vođenje sustava, te pristup mreži odjeli su koji imaju koristi od sustava. Održavanje DeGIS koristi za izradu planova održavanja, olakšana im je analiza kritičnih dijelova sustava i dežurnim ekipama podaci su dostupni od 0-24h. Iz odjela za planiranje i razvoj imaju mogućnost brzog i učinkovitog izvlačenja podataka prilikom donošenja trogodišnjih i desetogodišnjih planova, kao i unos planiranih zahvata, te definiranje budućih trasa i lokacija postrojenja za potrebe projektiranja. Ostali odjeli također imaju velike koristi u vidu lako dostupnih podataka iz DeGIS-a.

O ovom poglavlju navedena su četiri slučaja primjene DeGIS-a u ODS-u. U prvom slučaju imamo prikaz trafostanice 35/10 kV, u drugom slučaju 10/0,4 kV. Treći slučaj prikazuje vod odnosno kabel i trafostanicu 10/0,4 kV. Zadnji slučaj prikazuje trafostanicu koja je u planu izrade.

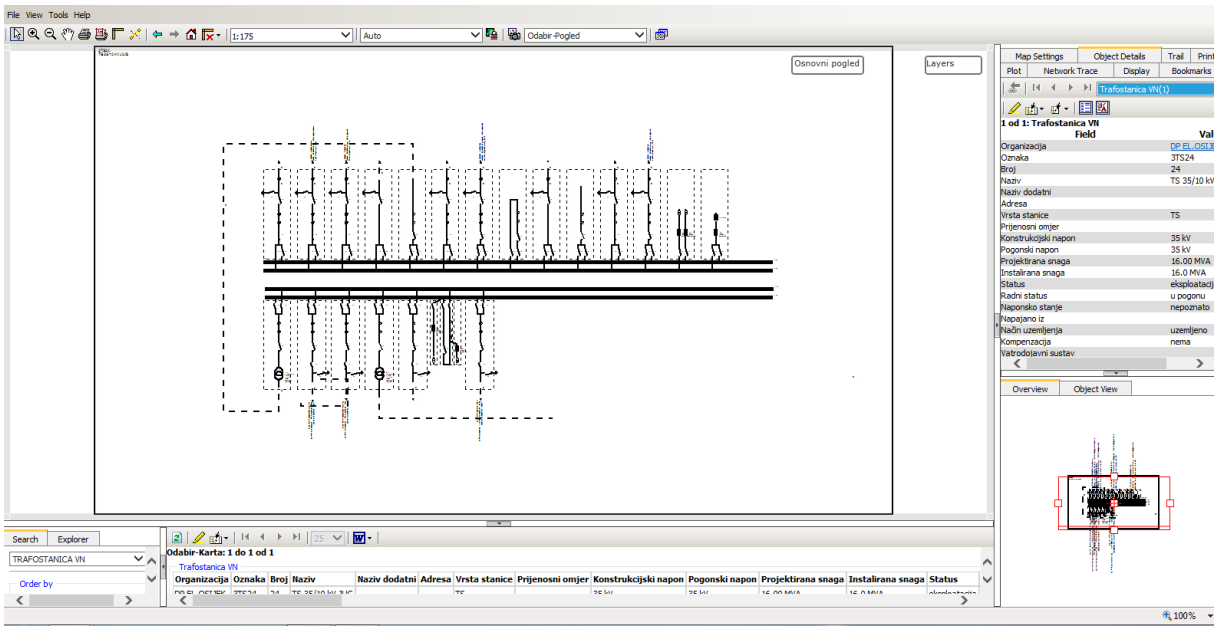
Slučaj 1

U ovom primjeru prikazan je interni i eksterni svijet trafostanice 35/10 kV. Na slici 6.1. prikazana je trafostanica TS 35/10 kV JUG i njen eksterni svijet. Prostorni podatci koji su vidljivi prema slici su ti da se trafostanica nalazi u Drinskoj ulici u bilizini katastarske čestice 9824/8. Također su prikazani kabeli i zračni vodovi. Kabeli, vodovi i trafostanica čine strukturne podatke. Vodovi i kabeli napajaju preko Drinske ulice trafostanice 10/0,4 kV. U programu se crvenom bojom prikazuju vodovi srednjeg i visokog napona dok su plavom bojom prikazani vodovi niskog napona. Na slici možemo vidjeti položaj trafostanice u prostoru i na temelju njega donositi planove i odluke. Također vidimo raspored vodova u prostoru što nam omogućuje bolje planiranje i odlučivanje. Ovakav prikaz omogućuje jednostavniju pripremu podataka prije izlaska na teren. S desne strane nalazi se prozor s podacima o trafostanici, te širi prikaz područja koje pretražujemo. Ispod samog prikaza odnosno satelitske snimke nalazi se prozor za pretraživanje, odnosno korisničko sučelje ekspertnog sustava.



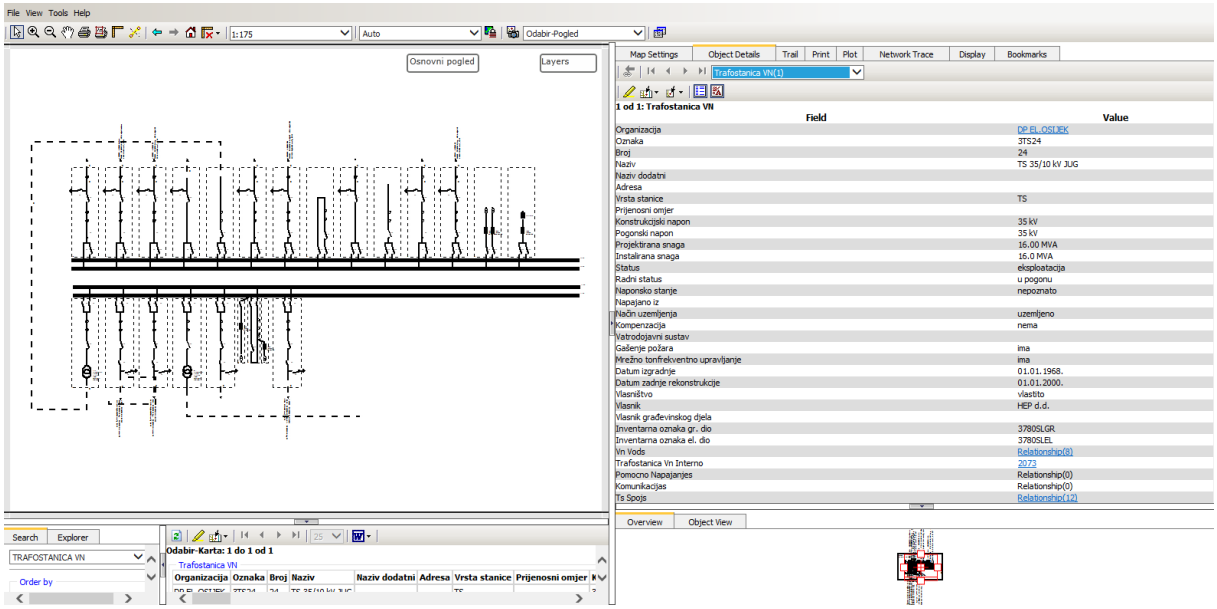
Slika 6.1. Eksterni svijet trafostanice TS 35/10 kV JUG

Možemo reći da svako postrojenje, trafostanica, rasklopište, razvodni ormari i sl. može imati svoj vlastiti interni (mikro) GIS. Eksterni svijet sastoji se od strukturnih i prostornih podataka. Slično je sa internim svijetom gdje se nalazi jednopolna shema kao strukturni podatak, te nazivi ulica koje se napajuju iz trafostanice kao prostorni podatak. Prema literaturi [8]: „Svi elementi nužni za vođenje (interni vod, sabirnica), kao i uređaji (transformator, osigurač, prekidač, mjerno mjesto) moraju imati svoju logičku i topološku vezu prema susjednim elementima.“ Na slici 6.2. prikazan je interni svijet trafostanice TS 35/10 kV JUG. Vidimo dvostruke sustave sabirnica 35 kV i 10 kV. Na sabirnicama 35 kV imamo dva trafo polja, četiri vodna polja, te jedno spojno i jedno mjerno polje. Na 10 kV sabirnicama imamo deset vodnih polja jedno spojno polje, te kompenzaciju. Sve ove informacije vrlo su važne kod odrađivanja poslova vezanih za ovu trafostanicu. Bilo da su to poslovi vezani za otklanjanje kvarova, vođenje pogona ili neki treći posao vrlo je važno poznavati internu, ali i eksternu okolinu. Na izvodima trafostanice napisano je koji vod, dakle kabelski ili zračni vod je spojen na određeni izvod. Vod je opisan u smislu njegove vrste, broja žila, presjeka itd. Također je opisano u kojoj ulici se nalazi vod, dakle njegov geografski položaj.



Slika 6.2. Interni svijet trafostanice TS 35/10 kV JUG

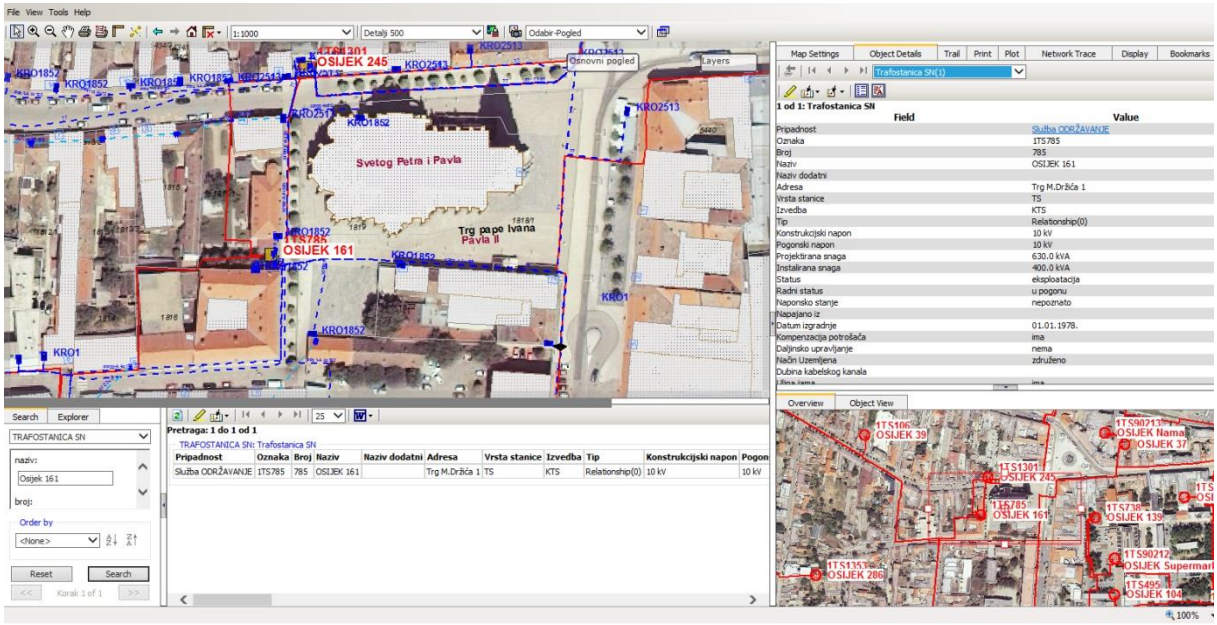
Na slici 6.3. nalazi se interni svijet (lijevo) i opis (desno), trafostanice TS 35/10 kV JUG. Prikaz internog svijeta objašnjen je na prethodnoj slici. U opisu trafostanice imamo razne podatke koji nam mogu biti od koristi. Neki od podataka koji mogu biti važni prilikom raznih planiranja i donošenja odluka su: naziv trafostanice, konstrukcijski i pogonski napon, pogonska i projektirana snaga, način uzemljenja, kompenzacija itd. Za određene izvještaje kao i za planiranje i projektiranje pretraživanje prema godini izgradnje odnosno godini rekonstrukcije mogu biti od velike pomoći. Ulaskom u interni svijet trafostanice vidljivo je da je pogonski napon trafostanice 35 kV, da je instalirana snaga 16 MVA, da je trenutno u pogonu. Također je vidljivo da nema kompenzacije, kao i da je trafostanica izgrađena 1968. godine, te da je posljednja rekonstrukcija odrađena 2000. godine.



Slika 6.3. Interni svijet i opis TS 35/10 kV JUG

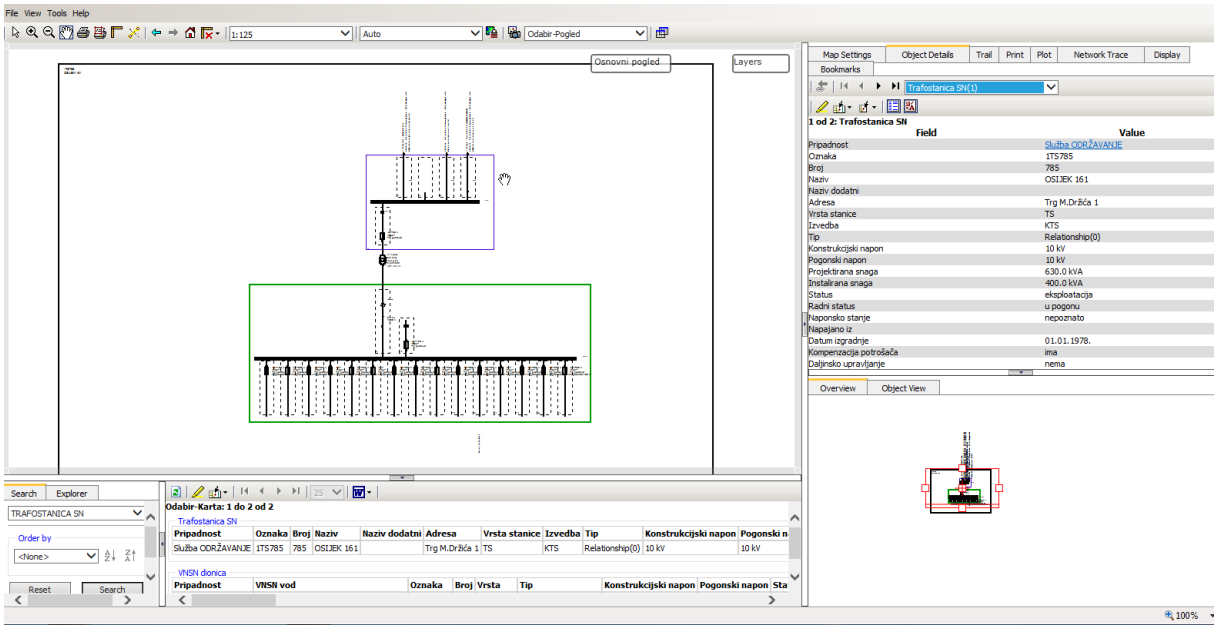
Slučaj 2

Slučaj 2 prikazuje interni i eksterni svijet trafostanice OSIJEK 161. Prema prostornim podatcima na slici vidiljivo je da se trafostanica nalazi na katastarskoj čestici 1815/1 te adresi Trg Marina Držića 1. Od strukturnih podataka na slici prikazani su transformatori, vodovi i rasklopni ormari. Na slici su crvenom bojom označeni vodovi 10 kV napona, te je vidljiv njihov geografski položaj. Plavom bojom su označeni izvodi iz trafostanice odnosno vodovi 0,4 kV. Vidljiv je položaj vodova odnosno koji vod napaja koji ormar. Položaji ormara su također prikazani slikom, što je vrlo važno prilikom pronalaska ormara u slučaju kvara ili rekonstrukcije.



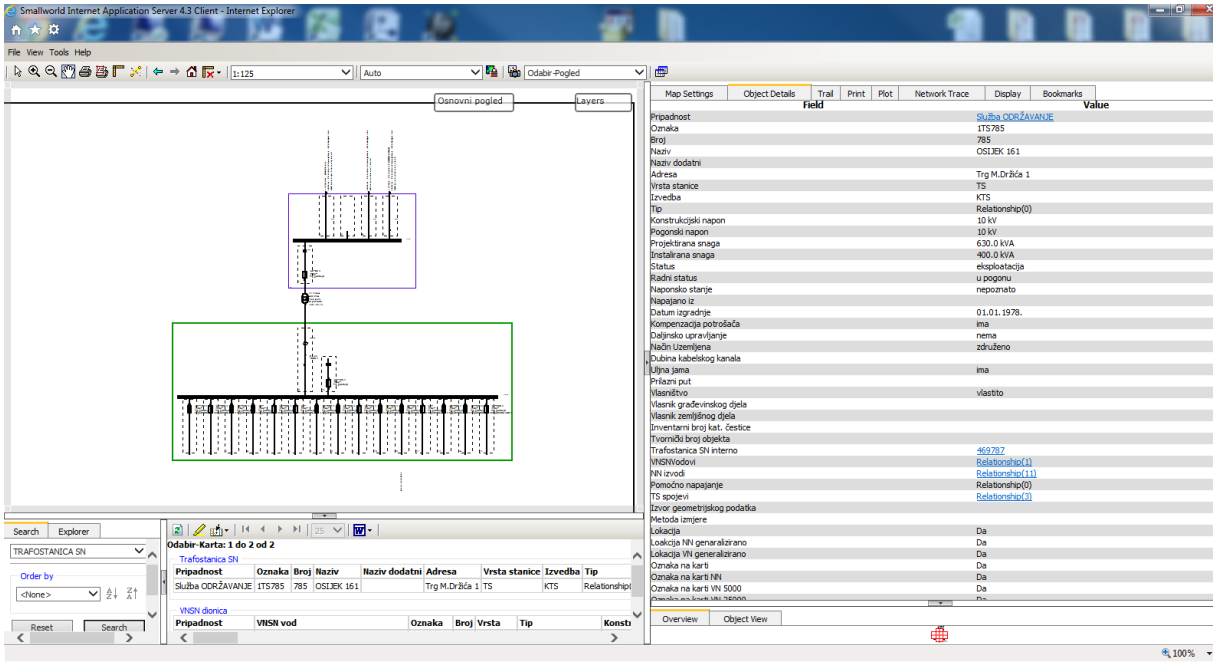
Slika 6.4. Eksterni svijet trafostanice OSIJEK 161

Prema jednopolnoj shemi na slici 6.5. vidimo da trafostanica ima tri dovoda napona 10 kV. Na slici 6.4. također je lako uočiti tri dovoda 10 kV označenih crvenom bojom. Ipak što se tiče odvoda, odnosno izlaza iz trafostanice, prema slici 6.4. situacija je nešto kompliciranija. Naime na slici 6.4. vidimo gdje određeni izlaz iz trafostanice ide, no zbog preklapanja puno je teže odrediti koliko određena trafostanica ima izvoda. Zbog toga nam značajno pomaže interni svijet i poput ovoga na slici 6.5., gdje se točno vidi broj dovoda, transformatora i odvoda. Ljubičastim okvirom prikazana su vodna polja 10 kV, a zelenim okvirom vodna polje 0,4 kV.



Slika 6.5. Interni svijet trafostanice OSIJEK 161

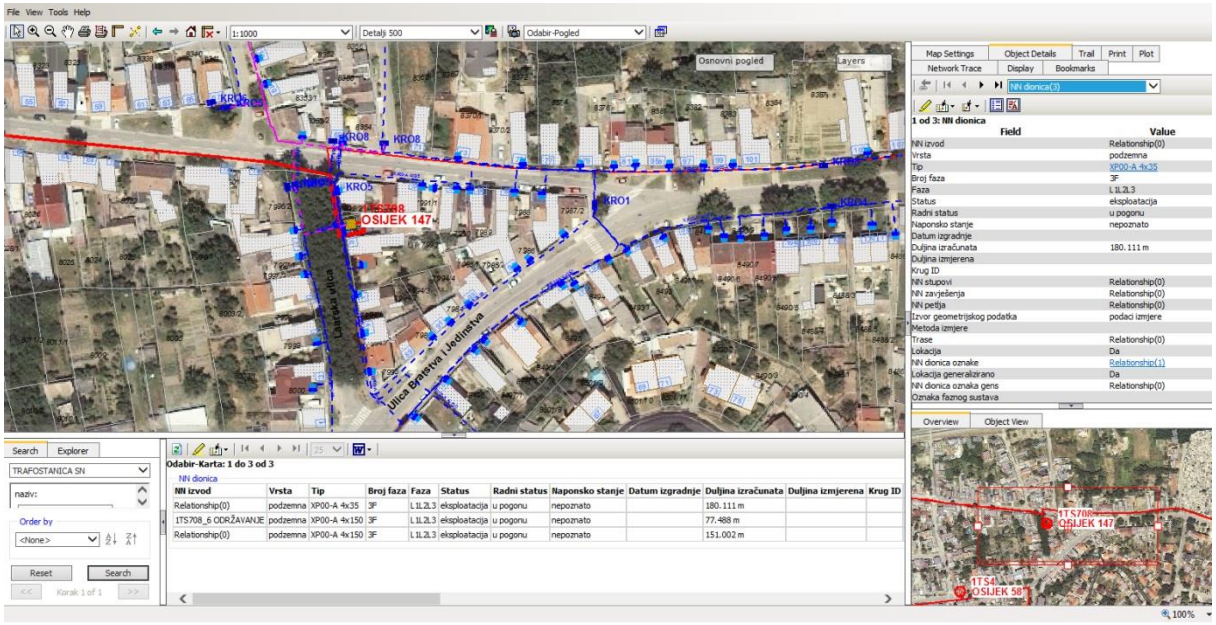
Na slici 6.6. nalazi se interni svijet (lijevo) i opis (desno), trafostanice OSIJEK 161. Slično primjeru na slici 6.3. prikazan je interni svijeta, te opis odabrane trafostanice. U opisu trafostanice nalaze se razni korisni podaci. Neki od podataka koji mogu biti važni prilikom raznih planiranja i donošenja odluka su: naziv trafostanice, konstrukcijski i pogonski napon, pogonska i projektirana snaga, način uzemljenja, kompenzacija itd. Za određene izvještaje kao i za planiranje i projektiranje pretraživanje prema godini izgradnje odnosno godini rekonstrukcije mogu biti od velike pomoći. Ulaskom u interni svijet trafostanice vidljivo je da je pogonski napon trafostanice 10 kV, da je instalirana snaga 400 kVA, dok je projektirana snaga 630 kVA. To znači da je u trafostanici trenutno transformator snage 400 kVA, dok ostala infrastruktura trafostanice ima mogućnost rada sa snagom 630 kVA Također je vidljivo da postoji kompenzacije, kao i da je trafostanica izgrađena 1978. godine, te da nije bilo kasnije rekonstrukcije.



Slika 6.6. Interni svijet i opis trafostanice OSIJEK 161

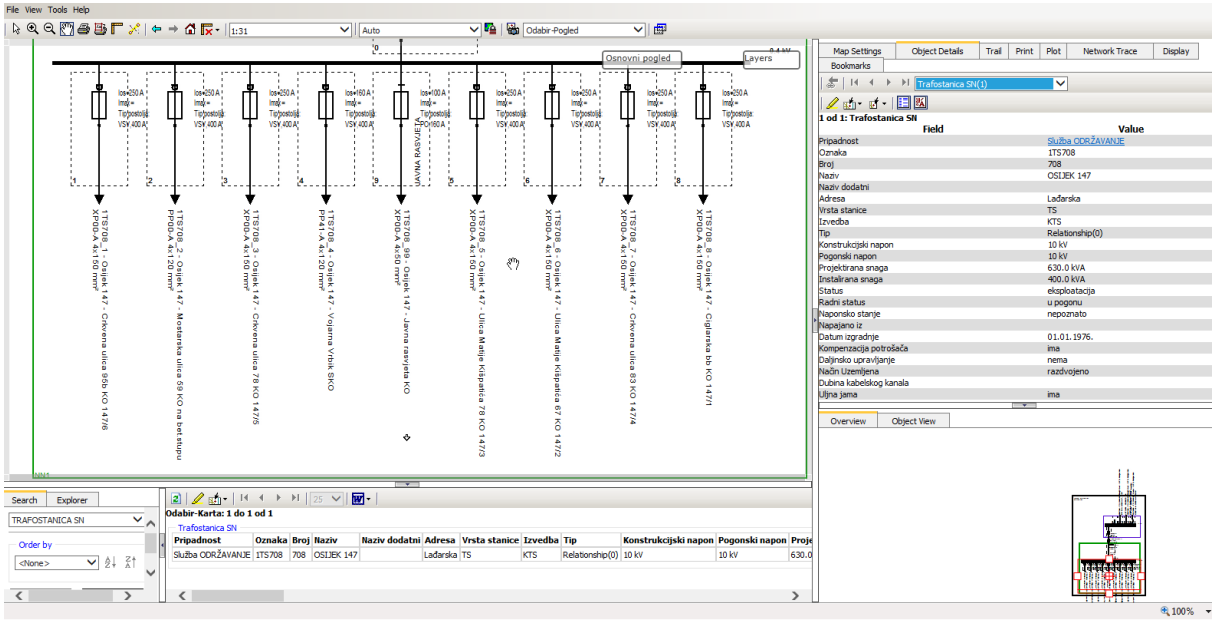
Slučaj 3

Slučaj 3 prikazuje interni i eksterni svijet trafostanice OSIJEK 147. Prostorni podatci na slici 6.7. prikazuju da se trafostanica nalazi u Lađarskoj ulici na katastarskoj čestici 7992/1. Strukturni podatci na slici su trafostanica, vodovi i razvodni ormari. Na slici su crvenom bojom označeni vodovi 10 kV napona, te je vidljiv njihov geografski položaj, kao i da se radi o dva 10 kV voda. Plavom bojom su označeni izvodi iz trafostanice odnosno vodovi 0,4 kV. Vidljiv je položaj vodova odnosno koji vod napaja koji ormar. Vidljivo je da se iz trafostanice napajaju potrošači u Crkvenoj ulici (nekadašnja Ulica Bratstva i Jedinstva), Kišpatićevoj, Ciglarskoj i Lađarskoj ulici. Položaji ormara su također prikazani slikom, što je vrlo važno prilikom pronalaska ormara u slučaju kvara ili rekonstrukcije.



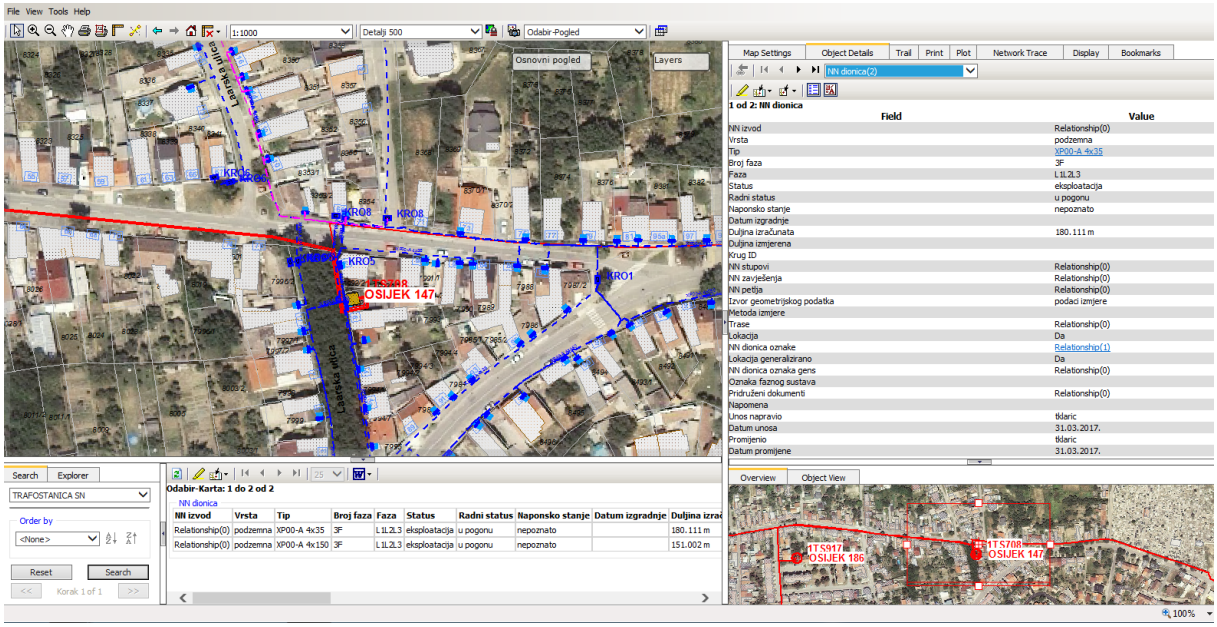
Slika 6.7. Eksterni svijet trafostanice OSIJEK 147

Prema jednopolnoj shemi na slici 6.8. vidimo da trafostanica ima devet izvoda napona 0,4 kV. Osam izvoda koristi se za napajanje potrošača dok se jedan izvod koristi za napajanje javne rasvjete. Na slici su prikazani osigurači, te njihove struje. Svaki izvod opisan je na način da su prikazane ulice koje napaja, te da je opisan sami vodič. Opis vodiča kao i jednopolna shema strukturni su podatci, dok su prostorni podatci adrese koje vodovi napajaju.



Slika 6.8. Izvodi niskog napona trafostanica OSIJEK 147

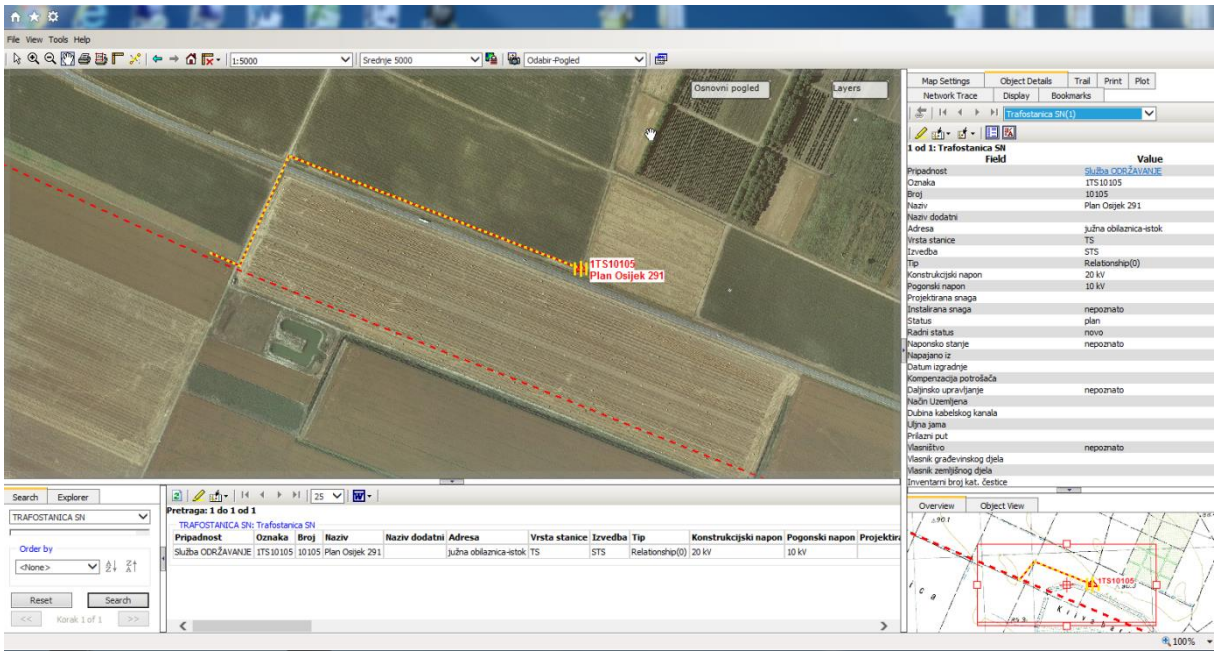
Na slici 6.9. vidimo eksterni svijet trafostanice OSIJEK 147, vodove 10 kV, te vodove 0,4 kV. Označavanjem voda na slici dobili smo uvid u njegov interni svijet. Dakle u eksternom svijetu označili smo vod koji napaja Lađarsku ulicu (označen je ljubičastom bojom), a s desne strane smo dobili interni svijet tog voda. Prema podacima vidimo da se radi o podzemnoj vrsti voda, odnosno kabelu, vidimo tip kabela, odnosno broj žila, te presjek. Također vidimo da je kabel u pogonu, te da njegova duljina iznos 180 metara. Također vidimo tko je i kada unio podatke o ovom vodu, te tko je i dali je napravio kasnije izmjene. Osim toga jasno je vidljivo koji su ormari napajani tim kabelom, te je lako ustanoviti gdje je nastao kvar, ako netko od potrošača prijavi nestanak struje.



Slika 6.9. Eksterni svijet trafostanice i interni svijet voda

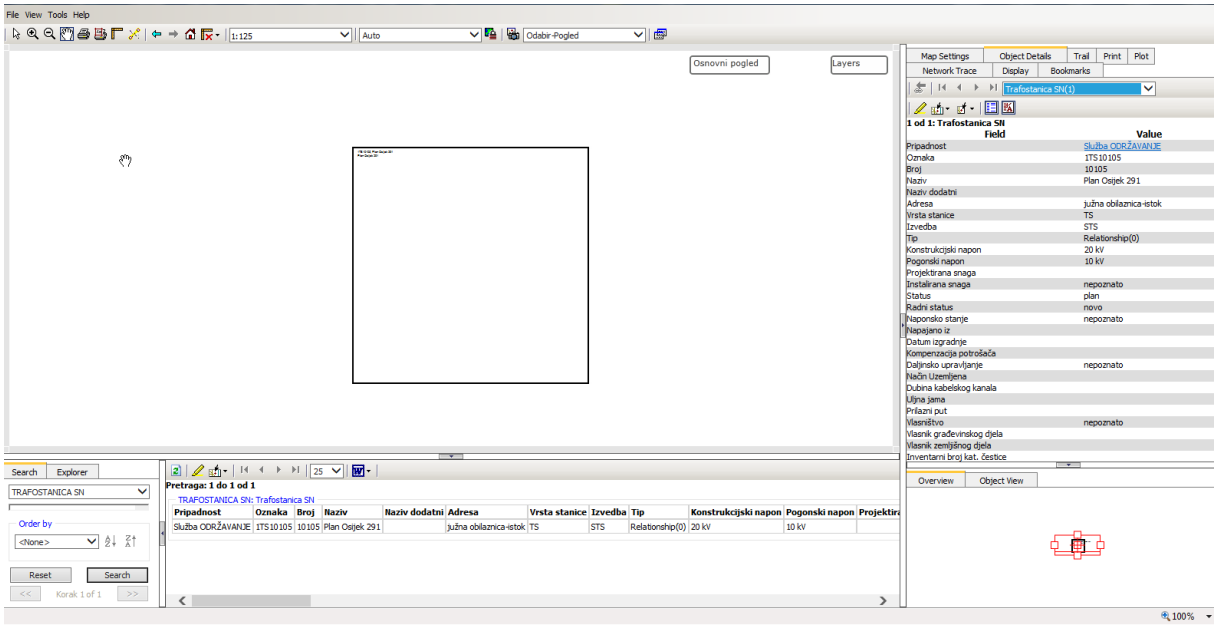
Slučaj 4

Slučaj 4 razlikuje se od ostala tri po tome što se njime prikazuje trafostanica koja je tek u planu izgradnje. Prema slici 6.10. je vidljivo da vod koji će povezivati dalekovod i trafostanici označen žuto crvenom bojom, kao i sama trafostanica. Dakle sustav ima mogućnost unošenja planova izgradnje infrastrukture, te se plan ovim načinom obilježavanja razlikuje od izgrađenih djelova. Ovo je vrlo korisno u slučaju da se iz nekog drugog odjela planira izgradnja na toj ili vrlo sličnoj lokaciji. Uvidom u DeGIS osoba može vidjeti da je plan već napravljen, te se na taj način otlanja mogućnost obavljanja istog posla dva puta. Jedini prostorni podatak u ovom slučaju nalazi se u opisu gdje je vidljivo da će se trafostanica nalaziti na istočnoj strani južne obilazince.



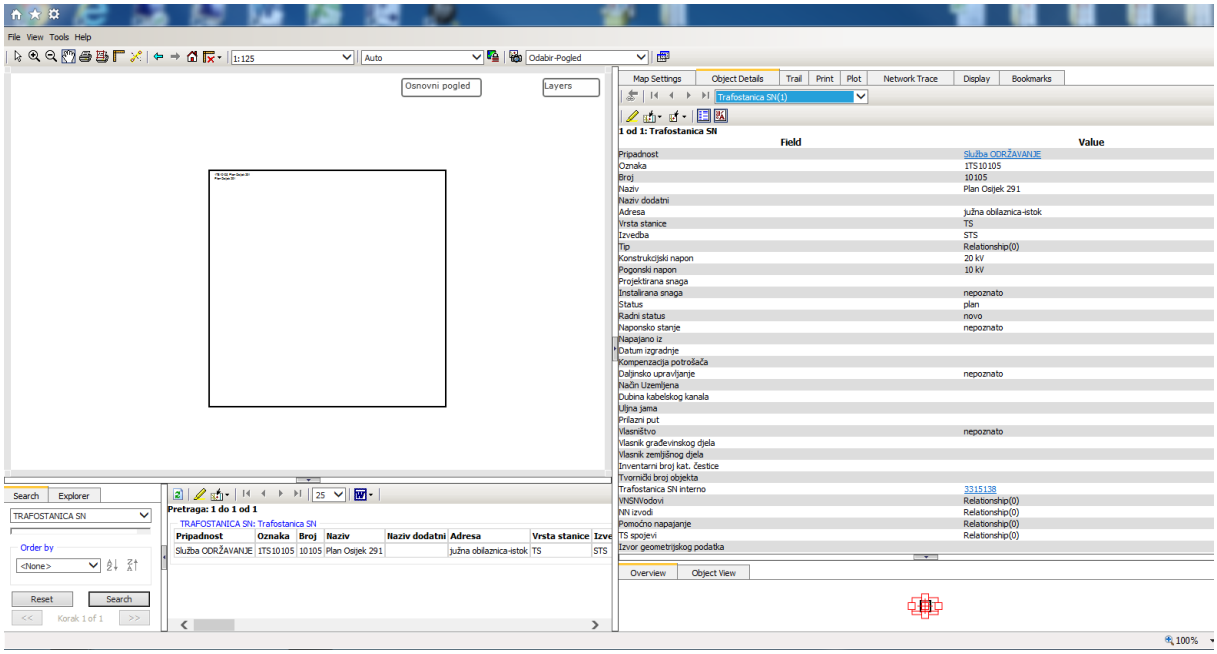
Slika 6.10. Eksterni prikaz trafostanice koja je u planu

Na slici 6.11. prikazan je interni svijet trafostanice Plan Osijek 291. Kako je trafostanica u planu, te nije izgrađena u njenom internom svijetu ne nalazi se ništa. Izgradnjom trafostanice, slično kao u prethodnim primjerima unosi se broj dovoda, odnosno izvoda, broj transformatora, te ostale opreme.



Slika 6.11. Interni svijet trafostanice u planu

Iako interni svijet ne postoji kao što prikazuju slike 6.11. i 6.12. opis trafostanice donosi neke detalje o samoj trafostanici. Iz opisa je vidljivo da će se trafostanica nalaziti na istočnoj strani južne obilaznice. Također vidimo da je izvedba STS, odnosno stupna trafostanica, da je konstruirani napon 20 kV, dok će pogonski napon biti 10 kV.



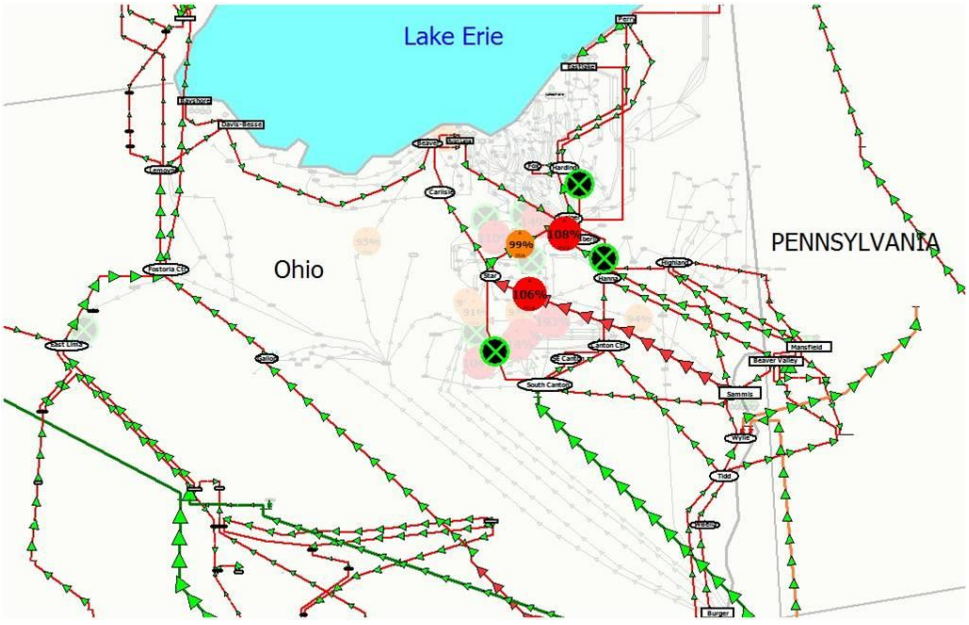
Slika 6.12. Interni svijet i opis trafostanice u planu

6.2. GIS funkcija u programskom paketu *PowerWorld*

Jedna od GIS funkcija unutar programskog paketa *PowerWorld* (*PW*) mogućnost je određivanja udaljenost između bilo koje dvije točke zemljopisne dužine i širine. Modul koji računa udaljenost između točaka pretpostavlja da je zemlja sfera te na temelju zemljopisnih koordinata izračunava udaljenost i prikazuje je u kilometrima ili miljama. Mogućnost pretvorbe x,y koordinata prikazanih na ekranu u koordinate zemljopisne dužine i širine još je jedna GIS funkcija u PowerWorld-u [15].

Simulator omogućava postavljanje pozadinske grafike uvozom ESRI datoteka (*shapefiles*). ESRI datoteke pomoću vektorskih formata predstavljaju prostorne podatke. Podatci iz ESRI datoteka sastoje se od grupa linija ili točaka koje predstavljaju pozadinu za dijagram simulacije [15].

GIS mogućnosti koje ima *PowerWorld* simulator mogu se svesti na mogućnost učitavanja karti, odnosno ESRI datoteka. Učitane karte postaju dio simulacije čineći pozadinu. Ako usporedimo DeGIS i GIS alate *PowerWorld*-a primjećujemo da se znatno razlikuju. DeGIS ima mogućnost pretraživanja pomoću simbolike dok GIS alati *PW* simulatora imaju mogućnost pretraživanja jedino pomoću koordinata. Karte u DeGIS-u sadrže satelitske snimke te detaljno opisuju prostor, dok PW simulator nema mogućnost uvoza karti sa satelitskim snimkama. Još jedna velika razlika između *PW* simulatora i DeGIS-a je to što su strukturni podatci simulatora, simulacije sa prikazom električnih prilika u mreži, dok se strukturni podatci DeGIS-a odnose na infrastrukturne podatke mreže. Na slici 6.13. prikazana je GIS funcija u *PW* simulatoru.



Slika 6.13. GIS funkcija u *PowerWorld*-u [16]

Dakle možemo zaključiti da DeGIS ima veće mogućnosti kad su u pitanju geografski podatci u odnosu na *PW* simulator te da se strukturni podatci razlikuju, gdje su u DeGIS-u pohranjeni infrastrukturni, a u *PW* simulatoru podatci, odnosno simulacije električnih prilika u mreži. Ovakav zaključak ne čudi, jer je DeGIS software namjenjen za pomoć pri prostornom odlučivanju, kao što je *PW* simulator namjenjen za simulacije električnih prilika.

7. ZAKLJUČAK

U trećem i četvrtom poglavlju opisani su geografski informacijski sustav i ekspertni sustav kao osnovne sastavnice sustava za pomoć pri prostornom odlučivanju. Geografski informacijski sustavi temelje se na pronalaženju, prikazivanju i analizi geografski podataka. Ekspertni sustavi temelje se na umjetnoj inteligenciji, dakle možemo reći da koristeći naučeno znanje i postupke zaključivanja dolaze do rješenja određenih problema.

HEP Operator distribucijskog sustava za pomoć pri prostornom odlučivanju koristi program DeGIS. Grafički rezultati prikazani u šestom poglavlju dobiveni su korištenjem DeGIS-a. Rezultati prikazuju jednostavan i učinkovit pristup podatcima distribucijske mreže. Dakle vrlo je važno prilikom planiranja, projektiranja, održavanja i donošenja odluka vezanih za elemente i postrojenja distribucijske mreže poznavati njihov interni i eksterni svijet. Osim pregleda podataka korisnik je u mogućnosti napraviti izmjene ili nadopuniti sustav informacijama.

DeGIS kao sustav povezuje prostorne podatke sa infrastrukturnim podatcima operatora distribucijskog sustava. Očekuje se da se u budućnosti DeGIS poveže sa SCADA-om te CIS-om. Dakle, uz prostorne i infrastrukturne podatke dodatak bi bili podatci o stanju mreže iz SCADA sustava te podatci o potrošačima iz CIS-a. U budućem razvoju sustava za pomoć pri prostornom odlučivanju veliku ulogu će imati podaci u stvarnom vremenu ili podatci vrlo blizu stvarnom vremenu. Podaci sa udaljenih područja odnosno senzora postaju sve dostupniji i sve češće će biti implementirani u sustave za pomoć pri prostornom odlučivanju.

POPIS UPOTREBLJENE LITERATURE

[1] Ramanathan Sugumaran, John DeGroote, Spatial Decision Support Systems Principles and Practices, by Taylor and Francis Group, LLC 2011

[2] Tutić Dražen, Vučetić Nada, Lapaine Miljenko; Uvod u GIS; Geodetski fakultet, Zagreb, 2002

[3] John P. Wilson, A. Stewart Fotheringham, The Handbook of Geographic Information Science, by Blackwell Publishing Ltd, 2008

[4] Lisa D. Murphy , Geographic Information Systems: Are They Decision Support Systems?, School of Business, Indiana University, Bloomington, IN; Proceedings of the 28th Annual Hawaii International Conference on System Sciences, 1995

,

[5] Rolf A. de By, Principles of Geographic Information Systems, by ITC, Enschede, The Netherlands, 2001

[6] P. A. Longley, M. F. Goodchild, D. J. Maguire, D. W. Rhind, Geographical Information Systems and Science, John Wiley & Sons Ltd, 2005

[7] Havaš L., Jagić D. Tehnički glasnik 6, Veleučilište u Varaždinu, 2012

[8] Akmačić M. dipl.ing geod. HRVATSKI OGRANAK MEĐUNARODNE ELEKTRODISTRIBUCIJSKE KONFERENCIJE – HO CIRED; 1. savjetovanje; Šibenik, 18. - 21. svibnja 2008; HEP ODS d.o.o. Elektra Zagreb

[9] J. Giarratano, G. Riley, Expert Systems Principles and Programming, Third Edition, by PWS Publishing Company, 1998

[10] M. Ašenbrener Katić, Predstavljanje znanja: pregled područja;; Sveučilište u Rijeci, Odjel za informatiku

[11] J. Durkin, Expert Systems DESIGN AND DEVELOPMENT, Prentice Hall PTR Upper Saddle River, NJ, SAD, 1998

[12] Daniel J. Power, Power Enterprise, 2015, power@dssresources.com
URL: http://dssresources.com/faq/index.php?action=artikel&cat=&id=48&artlang=en (20.9.2017.)

[13] Prof. Dr. Yee Leung, Intelligent Spatial Decision Support Systems; The Chinese University of Hong Kong Department of Geography, and Center for Environmental Studies Shatin N.T., Hong Kong; Springer-Verlag Berlin· Heidelberg 1997.

[14] Jin-Yong Choi, Bernard A. Engel and Richard L. Farnsworth ,Web-based GIS and spatial decision support system for watershed management; IWA Publishing 2005

[15] Upute za korištenje: PowerWorld Simulator version 11 Manual
URL: https://www.powerworld.com/files/pw110UserGuide.pdf (20.9.2017.)

[16] PowerWorld Simulator: pregled,
URL: https://www.powerworld.com/products/simulator/overview (20.9.2017.)

SAŽETAK

U diplomskom radu detaljno je opisan sustav za pomoć pri prostornom odlučivanju u distribuciji električne energije. Teorijski su opisana dva glavna djela sustava za pomoć pri prostornom odlučivanju, geografski informacijski sustav i ekspertni sustav. Također je prikazan povjesni pregled sustava. U rezultatima je prikazan DeGIS sustav za pomoć pri prostornom odlučivanju u distribuciji električne energije koji se koristi u HEP Operatoru distribucijskog sustava.

Ključne riječi: Sustav za pomoć pri prostornom odlučivanju, distribucija električne energije, geografski informacijski sustav, ekspertni sustav, prostorne informacije.

ABSTRACT

The diploma thesis describes spatial desicion support system in distribution of electrical energy. Also, two main parts of spatial desicion support system, geographical information system and expert system are described. Historical review of system is also presented. The results show DeGIS, spatial desicion support system used in HEP Distribution system operator.

Key words: Spatial desicion support system, distribution of electrical energy, geographical information system, expert system, spatial information.

ŽIVOTOPIS

Mihael Zaspan rođen je 14.5.1993. u Našicama, sa prebivalištem u Lacićima. U Magadenovcu, 2008. završava osnovnu školu „Matija Gubec“ zatim upisuje srednju elektrotehničku školu u Našicama koju završava 2012. godine. Tijekom osnovnoškolskog obrazovanja redovito sudjeluje na županijskim natjecanjima iz matematike.

2012. godine upisuje preddiplomski sveučilišni studij elektrotehnike na Elektrotehničkom fakultetu u Osijeku. Prediplomski studij završava 2015. te upisuje diplomski studij elektrotehnike smjer elektroenergetski sustavi. Aktivno se služi engleskim jezikom, računalom, te je informatički pismen (MS Word, MS Excel, MS PowerPoint).

Aktivno se bavi sportom te ostatak slobodnog vremena voli provoditi fotgrafirajući.

U Osijeku, 21.9.2017.

Mihael Zaspan

PRILOZI