Fakultet elektrotehnike i računarstva – Zagreb

Zavod za elektroniku, mikroelektroniku, računalne i inteligentne sustave

Predmet: ZER14D1 Predstavljanje znanja u informacijskim sustavima

Smjer: Jezgra računarstva

Šk. god. 2002/2003

Nastavnik: Prof. dr. sc. Nikola Bogunović

Metoda prekrivanja i ocjenjivanje znanja upotrebom neizrazite logike

seminarski rad

Branko Žitko

Zagreb, rujan 2004

Kazalo:

1 Uvod

Informacijska i komunikacijska tehnologija (IKT) postala je neizostavan dio obrazovnih sustava koji pomažu učiteljima prilikom realizacije nastave ili zamjenjuju istu nastavu kombiniranjem brojnih metoda i načina ostvarivanja procesa učenja i poučavanja. Primjena tehnologije i razvoj edukacijskih sustava pripomogli su stvaranju paradigme e-učenja koja danas obuhvaća ne samo inteligentne sustave namijenjene potpori procesa učenja i poučavanja, već i ostale medije kao što su CD-ROM, poučavanje zasnovano računalom, video-konferencije, distribucija sadržaja učenja pomoću satelita i virtualne mreže znanja. U današnje vrijeme se razvoj na polju e-učenja usmjerava na stvaranje sustava za poslovanje učenjem (SPU) [BRAN2000] i inteligentne tutorske sustave (ITS) [BRSW1996]. Za razliku od SPU-ova koji služe uglavnom distribuciji elektroničkih sadržaja na zahtjev učenika, ITS-ovi implementiraju inteligenciju u nekoliko segmenata ostvarivanja procesa učenja i poučavanja.

Općenito, ITS je sustav zasnovan na nekoj od tehnologija za prikazivanje znanja. Prikazivanje znanja u ITS-ovima uključuje ne samo znanje učenika, već i područno znanje koje učitelj upotrebljava kod kreiranja znanja o nastavnom procesu. Navedene vrste znanja, te korisnici ITS-ova uzrokovali su i modularnu arhitekturu sustava koja se sastoji od:

- modula stručnjaka – za oblikovanje područnog znanja koje će kasnije učitelj koristiti za stvaranje nastavnog sadržaja namijenjenog učeniku,
- modula učitelja – za oblikovanje nastavnog sadržaja na osnovu područnog znanja,
- modula učenika – koji uključuje informacije o profilu učenika i znanje o njegovoj uspješnosti u procesu učenja i poučavanja,
- komunikacijskog modula – koji povezuje prethodno navedene module i same korisnike sa sustavom.

Modul učenika pomoću kojeg se ostvaruje proces učenja i poučavanja obuhvaća i testiranje učenikovog znanja nakon čega se generira ocjena i preporuke za daljnji rad. U ovom radu se opisuje jedna od metoda za testiranje i ocjenjivanje znanja učenika koja je implementirana u Tutor-Expert sustavu (TEx-Sys) [STAN1997].

TEx-Sys je po definiciji inteligentna hipermedijska autorska ljuska što znači da spada u klasu inteligentnih autorskih sustava (IAS) koji služe za generiranje ITS-ova. Prikaz područnog znanja u sustavu TEx-Sys se zasniva na tehnologiji semantičkih mreža s okvirima [QUIL1968]. Osnovni elementi semantičke mreže su čvorovi koji predstavljaju koncepte i veze koje povezuju čvorove, odnosno stvaraju relacije među konceptima. Čvorovi se klasificiraju na generičke čvorove koji predstavljaju samu klasu objekata, dok čvorovi primjeraka su zapravo primjerci klase, odnosno objekti i povezani su s odgovarajućim generičkim čvorom vezom PRIMJERAK_OD. Često se kod semantičkih mreža koriste sljedeći tipovi veza [ANAS1998]:

- veze pripadnosti čvoru služe za hijerarhijsku kategorizaciju čvorova u semantičkoj mreži. Primjer je veza JE (IS_A) koja govori o odnosu između podčvora i nadčvora, gdje podčvor nasljeđuje svojstva nadčvora;

- veze koje govore o primjercima čvorova, kao što je veza PRIMJERAK_OD (INSTANCE_OF) koja čvor primjerka povezuje s generičkim čvorom;
- veze koje strukturalno raščlanjuju čvor na dijelove, primjerice veza DIO_OD (PART_OF).

Uz takvu skupinu veza javlja se potreba korištenja različitih vrsta relacija među generičkim čvorovima i relacije između čvorova primjeraka. Tako je na slici 1.1 dan primjer veze VOLI koja povezuje mačku Feniks sa psom Fidom i obrnuto.

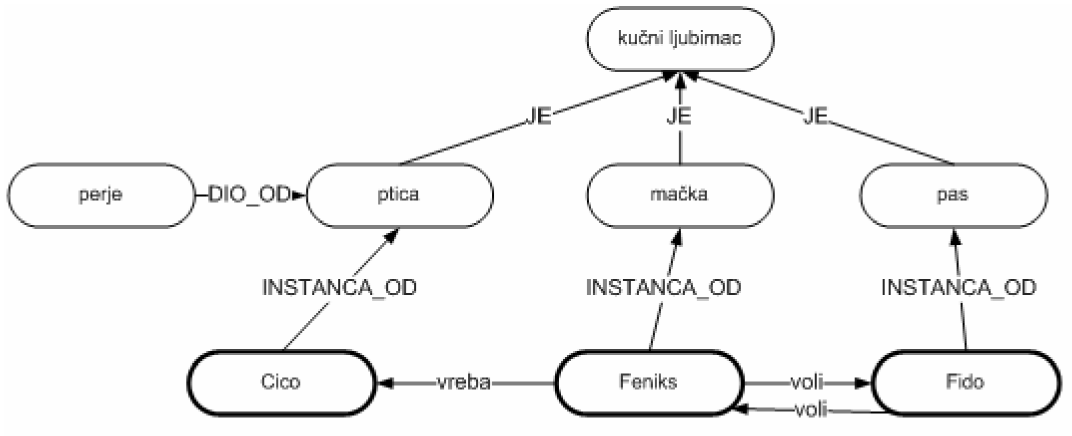

Slika 1.1 Čvorovi i veze u semantičkoj mreži

Okviri u semantičkoj mreži služe za definiranje svojstava (atributa) čvorova i dijele se ovisno o vrsti čvora kojem pripadaju na generičke okvire koji samo definiraju svojstva generičkog čvora, a vrijednosti tih svojstava nalaze se u okviru primjerka koji shodno tome pripadaju čvoru primjerka. Na slici 1.2 generički čvor osoba sadrži okvir bez vrijednosti svojstava, dok čvorovi primjeraka Ana Anić i Pero Perić sadrže vrijednosti generičkog okvira osobe.

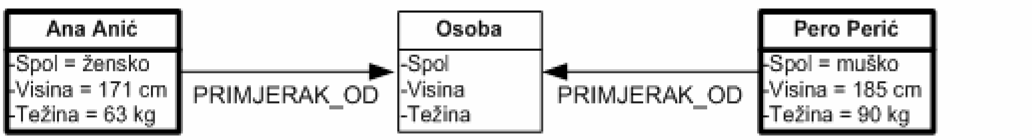

Slika 1.2 Semantička mreža s okvirima

Veze koje određuju pripadnosti čvoru kao što je veza JE omogućavaju nasljeđivanje svojstava generičkih okvira. Tako u semantičkoj mreži na slici 1.3 čvor zaposlenik je naslijedio svojstva okvira od osobe i proširio ga s novim svojstvom.

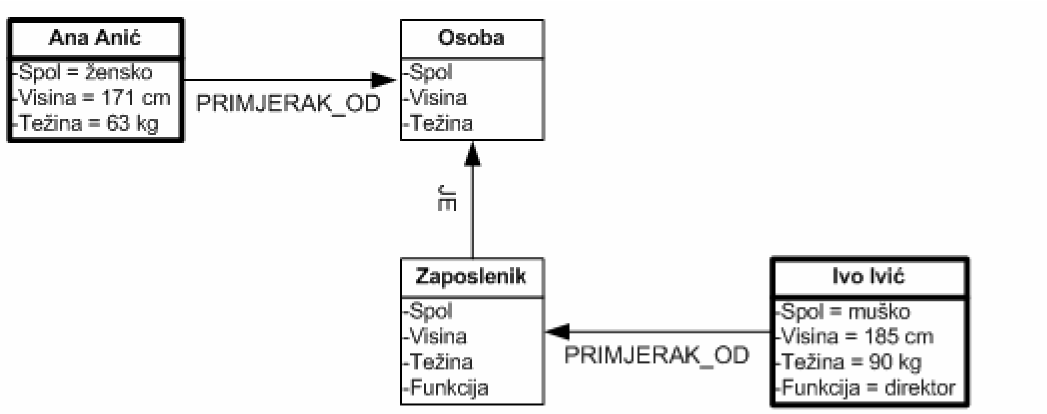

Slika 1.3 Nasljeđivanje u semantičkoj mreži s okvirima

Nastavni sadržaj koji se izlaže učeniku u sustavu TEx-Sys sadržavat će međusobno povezane čvorove koji se dodatno opisuju pomoću okvira. U poglavlju 2 se opisuje tehnika testiranja znanja učenika zasnovana na metodi prekrivanja prikaza znanja u sustavu TEx-Sys. Poglavlja 3 i 4 opisuju prijedlog novog načina ocjenjivanja rezultata testiranja korištenjem metode prekrivanja, time da se u poglavlju 3 za svaki element semantičke mreže s okvirima određuje faktor važnosti, dok se u poglavlju 4 primjenjuje neizrazita logika prilikom kreiranja neizrazitog sustava za određivanje konačne ocjene testiranog znanja.

2 Metoda prekrivanja prikaza znanja i ocjenjivanje u sustavu TEx-Sys

U sustavu TEx-Sys su implementirane dvije metode testiranja znanja učenika. Metoda kviza na osnovu povezanih čvorova i njihovih okvira dinamički generira pitanja i nudi odgovore učeniku na izbor. Druga metoda prekrivanja koristi područno znanje radi generiranja problemskog znanja koje učenik pokušava što više približiti područnom znanju. Uspoređivanjem navedenih znanja se izračunava ocjena uspješnosti učenikova testiranja. Tehnika prekrivanja znanja promatra razlike između učenika i učitelja/stručnjaka, tako da je omogućena spoznaja kako pogrešnog poimanja tako i nedostatka znanja učenika. Pri tome se uspoređuju tri vrste baza znanja:

- **<STRUČNJAK>** baza znanja sa znanjem stručnjaka za izabrano područno znanje,
- **<ZADATAK>** baza znanja sa zadatkom čijem rješavanju pristupa učenik,
- **<RJEŠENJE>** baza znanja s rješenjem kojeg je učenik polučio.

Ove navedene baze znanja su realizirane tehnikom semantičkih mreža s okvirima.

Kada učenik odluči provjeriti svoje znanje, tada pokreće modul za testiranje u kojem ga se traži da izabere jedan od tri vrste zadataka za rješavanje i to:

- Zadatak 1: Za izabrano područno znanje obrisane su sve veze te je znanje u zadatku prikazano samo s čvorovima. Učenik mora unosom veza popuniti strukturu izabranog područnog znanja.
- Zadatak 2: Generira se fragment znanja iskazan određenim brojem čvorova iz baze izabranog područnog znanja s ne manje od 30% i ne više od 70% od ukupnog broja čvorova u izabranoj bazi znanja. Učenik treba izvršiti nadopunu generiranog fragmenta znanja s nedostajućim čvorovima i potrebnim vezama tih čvorova prema ostalim u izabranoj bazi znanja.
- Zadatak 3: Generira se fragment znanja iskazan određenim brojem čvorova iz baze izabranog područnog znanja. Broj čvorova koji se generiraju u zadatku nije manji od 50% od ukupnog broja čvorova. Pored toga, u fragmentu znanja generator slučajnih brojeva generira i određeni broj pogrešnih veza. Od učenika se traži da:
    [1] pronađe čvorove s pogrešnim vezama, raskine pogrešne veze i uspostavi točne veze,
    [2] nadopuni generirani fragment znanja s nedostajućim čvorovima i potrebnim vezama tih čvorova prema ostalim u izabranoj bazi znanja.

Izborom zadatka se na osnovu baze znanja <STRUČNJAK> brisanjem čvorova, te brisanjem i/ili pogrešnim povezivanjem čvorova generira baza <PROBLEM>. Rješavanjem zadatka učenik može sa čvorovima obavljati sljedeće radnje: brisati čvorove, dodavati nedostajuće čvorove i dodavati nove čvorove koji nisu u bazi znanja stručnjaka. Sa vezama su sljedeći postupci: dodavanje nove veze s novo uvedenim čvorovima koji nisu u bazi znanja stručnjaka, brisanje točne veze, brisanje pogrešne veze, dodavanje točne veze, dodavanje pogrešne veze i dodavanje nedostajuće veze. U tom smislu čvorovi i veze u bazi <RJEŠENJE> s obzirom na čvorove i veze u bazama znanja <STRUČNJAK> i <ZADATAK> mogu imati različite statuse.

2.1 Statusi čvorova i veza

Postupci nad čvorovima i vezama u bazama znanja određuje njihov status, pa tako status čvora može biti:

- **<Dodan>** Čvor jest u bazi znanja <STRUČNJAK>, nije u <ZADATAK> i jest u <RJEŠENJE>.
- **<Brisan>** Čvor jest u bazi znanja <STRUČNJAK>, jest u <ZADATAK> i nije u <RJEŠENJE>.
- **<Nedostaje>** Čvor jest u bazi znanja <STRUČNJAK>, nije u <ZADATAK> i nije u <RJEŠENJE>.
- **<Bez promjene>** Čvor jest u bazi znanja <STRUČNJAK>, jest u <ZADATAK> i jest u <RJEŠENJE>.

- **<Novi>** Čvor nije u bazi znanja <STRUČNJAK> , nije u <ZADATAK> i jest u <RJEŠENJE>.

Poput čvorova i za veze se redom definira status:

- **<Brisana pogrešna>** Veza nije u bazi znanja <STRUČNJAK>, jest u <ZADATAK> i nije u <RJEŠENJE>.
- **<Dodana točna>** Veza jest u bazi znanja <STRUČNJAK>, nije u <ZADATAK> i jest u <RJEŠENJE>.
- **<Bez promjene>** Veza jest u bazi znanja <STRUČNJAK>, jest u <ZADATAK> i jest u <RJEŠENJE>.
- **<Nedostajuća>** Veza jest u bazi znanja <STRUČNJAK>, nije u <ZADATAK> i nije u <RJEŠENJE>.
- **<Zadana pogrešna>** Veza nije u bazi znanja <STRUČNJAK>, jest u <ZADATAK> i jest u <RJEŠENJE>.
- **<Brisana točna>** Veza jest u bazi znanja <STRUČNJAK>, jest u <ZADATAK> i nije u <RJEŠENJE>.
- **<Dodana pogrešna>** Veza nije u bazi znanja <STRUČNJAK>, nije u <ZADATAK> i jest u <RJEŠENJE>.
- **<Nova>** Veza nije u bazi znanja <STRUČNJAK>, nije u <ZADATAK> i jest u <RJEŠENJE>.

Prekrivanjem čvorova i veza u bazama <STRUČNJAK>, <ZADATAK> i <RJEŠENJE> izvršava se rekonstrukcija učenikovog tijeka rješavanja postavljenog zadatka.

2.2 Ocjenjivanje učenika

Ocjenjivanje je proces razvrstavanja u kvalitativne kategorije. U našem odgojno-obrazovnom sustavu kategorije ocjene su iskazane opisnim kvalifikatorima, a skraćeno su izraženi kvantitativnim numeričkim kategorijama i to: izvrstan (5), vrlodobar (4), dobar(3), dovoljan (2) i nedovoljan (1).

U sustavu TEx-Sys su razrađeni kvalitativni kriteriji ocjenjivanja utemeljeni na bodovnim i opisnim kvalifikatorima i u vezi su s tehnikom prikaza znanja i odabranim semantičkim primitivima čvorova i veza u formalizmu za izgradnju modela učenika. U vezi s tim čvorovi iskazuju poznavanje objekata područnog znanja tj. poznavanje činjenica područnog znanja u izabranoj bazi znanja. Vezama se iskazuje misaoni proces uopćavanja činjenica područnog znanja u izabranoj bazi znanja, tj. odnos među objektima u izabranoj bazi znanja.

Kvantifikatori se uvode posebno za čvorove i posebno za veze. To su sada subjektivno procijenjene vrijednosti kojima se definiraju bodovni kriteriji za čvorove i veze.

kvantifikatori za čvorove	
status čvora	Kvantifikator
<Dodan>	+1,0
<Brisan>	-1,0
<Nedostaje>	-0,6
<Bez promjene>	0
<Novi>	0

kvantifikatori za veze	
status čvora	kvantifikator
<Brisana pogrešna>	+1,0
<Dodana točna>	+0,8
<Bez promjene>	+0,1
<Nedostajuća>	-0,2
<Zadana pogrešna>	-0,5
<Brisana točna>	-0,8
<Dodana pogrešna>	-1,0
<Nova>	0

Tablica 2.1 Kvantifikatori za čvorove i veze

Ukupan broj osvojenih bodova tijekom rješavanja zadatka je na ovaj način u neposrednoj vezi sa statusom čvorova i veza u bazi <RJEŠENJE>. Pored toga, za svaki se zadatak izračunava i ukupan broj bodova koje učenik može osvojiti u postavljenom zadatku. Ukupan broj bodova se izražava parametrom MAX (maksimalni broj bodova u postavljenom zadatku) i to posebno za čvorove, a posebno za veze. Dobivena vrijednost za parametar MAX se pridružuje opisnoj ocjeni izvrstan. To je ujedno i najveća ocjena koju učenik može dobiti za iskaz svojeg znanja. Kvalifikatori opisnih ocjena iskazani su s dvanaest kategorija i to devet za iskazivanje znanja, jedna kategorija je DOVOLJAN za prijelaz sa znanja na neznanje, te konačno dvije kategorije za iskazivanje neznanja. Svaka razina opisne ocjene i to od: manje od izvrstan do nedovoljan umanjuje se za po MAX/8, dok se ocjeni dovoljan dodjeljuje vrijednost 0. Opisne ocjene i intervali numeričkih pokazatelja prikazani su u tablici 2.2.

Ocjena		Numerički pokazatelj	
5	Izvrstan	MAX	9 razina
-5	manje od izvrstan	[7/8MAX, MAX>	
+4	više od vrlo dobar	[6/8MAX, 7/8MAX>	
4	vrlo dobar	[5/8MAX, 6/8MAX>	
-4	manje od vrlo dobar	[4/8MAX, 5/8MAX>	
+3	više od dobar	[3/8MAX, 4/8MAX>	
3	Dobar	[2/8MAX, 3/8MAX>	
-3	manje od dobar	[1/8MAX, 2/8MAX>	
+2	više od dovoljan	<0, 1/8MAX>	
2	Dovoljan	0	
-2	manje od dovoljan	[-1/8MAX, 0>	2 razine
1	Nedovoljan	[-2/8MAX, -1/8MAX>	

Tablica 2.2 Ocjene i numerički pokazatelji ocjena

Izračunavanje vrijednosti MAX za čvorove se dobiva po formuli

$$\text{MAX\_cvor} = \left|\langle \text{Nedostaje} \rangle\right| + \left|\langle \text{Dodan} \rangle\right| \tag{1}$$

gdje se zbraja ukupan broj čvorova različitih statusa uvećan za odgovarajući kvantifikator. Za određivanje boda za čvorove gledano na bazu <RJEŠENJE> se koristi formula

$$\text{BOD\_cvor} = \left|\langle \text{Dodan} \rangle\right| \times 1 + \left|\langle \text{Nedostaje} \rangle\right| \times (-0{,}6) + \left|\langle \text{Brisan} \rangle\right| * (-1) \tag{2}$$

Ocjena za čvorove se onda dobiva u kojem intervalu se nalazi bod za čvorove gledano na maksimalni broj bodova za čvorove.

Određivanje maksimalnog bodova za veze se pronalazi po formuli

$$\begin{aligned} \text{MAX\_veza} = {} & \left|\langle \text{Nedostajuća} \rangle\right| \times 0{,}8 + \left|\langle \text{Zadana pogrešna} \rangle\right| \times 1 + \\ & + \left|\langle \text{Bez promjene} \rangle\right| \times 0{,}1 + \left|\langle \text{Brisana točto } \rangle\right| \times 0{,}1 \end{aligned} \tag{3}$$

dok se bodovi za veze pronalaze po formuli

$$\begin{aligned} \text{BOD\_veza} = {} & \left|\langle \text{Pogrešna veza} \rangle\right| \times 1 + \left|\langle \text{Dodana točto } \rangle\right| \times 0{,}8 + \left|\langle \text{Bez promjene} \rangle\right| \times 0{,}1 + \\ & + \left|\langle \text{Nedostajuća} \rangle\right| \times (-0{,}2) + \left|\langle \text{Zadana pogrešna} \rangle\right| \times (-0{,}5) + \\ & + \left|\langle \text{Brisana točto } \rangle\right| \times (-0{,}8) + \left|\langle \text{Dodana pogrešna} \rangle\right| \times (-1) \end{aligned} \tag{4}$$

Ocjena znanja se određuje tako da se pronađe u kojem intervalu numeričkog pokazatelja za ocjene se nalaze bodovi za čvorove, odnosno veze u odnosu na maksimalni broj bodova za čvorove, odnosno veze.

Kvalifikatori za status čvorova i veza su slobodno određeni i nisu promjenjivi, te uvelike utječu na konačnu ocjenu znanja. Ocjenjivanje znanja učenika je subjektivan proces gdje se procjenjuje koliko učenik zna u odnosu na znanje učitelja. Takvo subjektivno ocjenjivanje se može pospješiti upotrebom neizrazite logike. Također se u sljedećem poglavlju uvodi nova metoda određivanja faktora važnosti elemenata semantičke mreže s okvirima gdje se svakom elementu s obzirom na njegovu povezanost s ostalim elementima određuje njegova važnost u cjelokupnoj semantičkoj mreži.

3 Dodjeljivanje faktora važnosti elementima semantičke mreže s okvirima

Za elemente semantičke mreže s okvirima se smatraju čvorovi, veze, svojstva i vrijednost svojstva u okvirima. Akcije dodavanja, promjene ili brisanja određenog elementa semantičke mreže s okvirima će utjecati na ukupan broj bodova za taj element. Ako se doda točan čvor u semantičku mrežu s okvirima, tada se ukupan broj bodova za čvorove povećava za faktor vrijednosti tog čvora. Ocjena za čvorove će se dobiti omjerom ukupnog broja bodova za čvorove i maksimalnog broja bodova za čvorove koji je suma svih faktora važnosti čvorova u područnom znanju.

3.1 Faktor važnosti čvorova

Problem određivanja faktora važnosti elemenata semantičke mreže s okvirima će se pokazati na primjeru čvorova. Semantička mreža se u matematičkoj teoriji može poistovjetiti s usmjerenim grafovima gdje čvor predstavlja vrh, a veza između dva vrha je luk. Usmjereni graf G je uređena trojka (V, L, I) gdje je V skup vrhova, L skup lukova, a I skup incidencije, odnosno skup uređenih trojki (v_i, l, v_j) gdje su v_i i v_j elementi skupa V, a l element od L. Uređena trojka (v_i, l, v_j) kaže da je vrh v_j povezan lukom l s vrhom v_i. Vrh v_j je dijete u odnosu na v_i, tj. vrh v_i je po vezi l roditelj od v_j. Faktor važnosti vrhova se određuje na osnovu njihovog položaja u usmjerenom grafu. Općenito se uzima da vrhovi roditelji imaju veći faktor važnosti od vrhova djece. Tako vrhovi v_1 i v_2 na slici 3.1 imaju veću važnost od vrhova v_5 i v_6 jer nemaju roditelja, odnosno v_5 i v_6 nemaju djece. Vrhovi v_3 i v_4 imaju djecu i roditelje pa je njihov faktor važnosti veći od faktora važnosti vrhova v_5 i v_6, odnosno manji od faktora važnosti vrhova v_1 i v_2. Ipak vrh v_3 je važniji od v_4 jer je on njegov roditelj.

Usmjereni graf na slici 3.1 se sastoji od dva podgrafa $G_1=(V_1, L, I_1)$ i $G_2=(V_2, L, I_2)$ kod kojih su skupovi incidencije I_1 i I_2, međusobno disjunktni, a njihova unija je zapravo skup incidencije usmjerenog grafa G. Isto vrijedi za skup vrhova V_1 i V_2, odnosno $V_1 \cap V_2 = \emptyset$ i $V_1 \cup V_2 = V$.

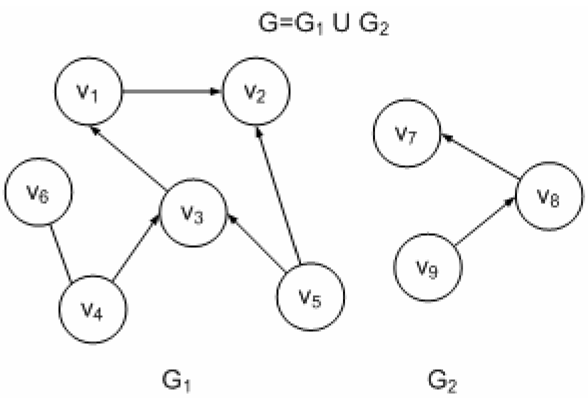

Slika 3.1 Usmjereni graf koji se sastoji od dva podgrafa

Faktor važnosti vrhova usmjerenog grafa se određuje tako da se izbroji ukupan broj roditelja izabranog vrha u posrednom i neposrednom odnosu na sve ostale vrhove u usmjerenom grafu. U slučaju da dva vrha imaju jednak broj roditelja u odnosu na sve ostale vrhove, onda će biti važniji onaj koji ima više posredne ili neposredne djece.

Prilikom određivanja faktora važnosti vrhova usmjerenog grafa G će nam pomoći matrica incidencije. Matrica incidencije *M(G)* za usmjereni graf G se pronalazi tako da se u i-tom retku i j-tom stupcu stavi broj veza između vrha v_j i vrha v_i. Za svaku matricu incidencije uvest ćemo i matricu M'(G) koja će biti jednaka matrici M(G) iz koje se elementi na dijagonali izbace, odnosno postave na 0.

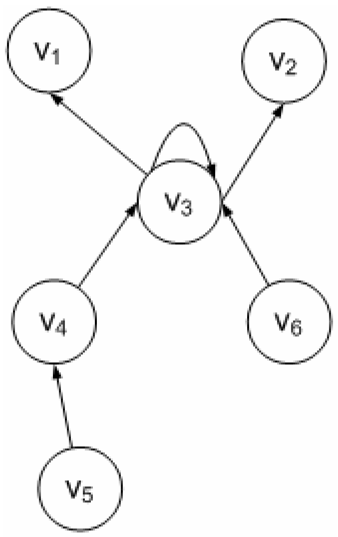

$$M(G) = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

Slika 3.2 Primjer matrice incidencije

Vrhu v_i usmjerenog grafa G na osnovu matrice incidencije *M'(G)* se može pridružiti uređena trojka (r_i, d_i) gdje je r_i ukupan broj roditelja, a d_i broj djece vrha v_i. Sada se prirodno definira funkcija f^m koja će broj djece vrha v_i izračunati zbrajanjem elemenata u redu i matrice *M'(G)* na m-tu potenciju, a broj roditelja zbrajanjem elemenata u stupcu i matrice $M'(G)^m$.

$$\begin{aligned} & f^m : V \to N_0 \times N_0 \\ & f^m(v_i) = (r_i^m, d_i^m) \\ & r^m{}_i = \sum_{k=1}^{n} a_{k,i}, d_i^m = \sum_{k=1}^{n} a_{i,k} \\ & M'(G)^m = \left[a_{i,j}\right] \\ & n = |V| \end{aligned} \qquad (5)$$

Po funkciji (5) se kod zbrajanja članova i-tog reda i i-tog stupca ne zbrajaju oni članovi matrice incidencije *M(G)* koji se nalaze na dijagonali jer je tada vrh povezan sa samim sobom, odnosno on je istovremeno roditelj i dijete sam sebi. Ovom funkcijom smo za svaki vrh dobili ukupan broj roditelja i djece u neposrednoj vezi s ostalim vrhovima usmjerenog grafa G.

Primjenom funkcije (6) smo dobili sljedeće rezultate za usmjereni graf na slici 3.2:

$$
\begin{aligned}
f^1(v_1) &= (0,1) \\
f^1(v_2) &= (0,1) \\
f^1(v_3) &= (2,2) \\
f^1(v_4) &= (1,1) \\
f^1(v_5) &= (1,0) \\
f^1(v_6) &= (1,0)
\end{aligned}
\tag{6}
$$

Ako se izračuna M'(G)^2 onda ćemo dobiti za svaki vrh usmjerenog grafa dobiti broj roditelja i djece u posrednoj vezi gdje se gledaju dva nivoa povezanosti. Na primjer, vrhovi v_1 i v_2 za djecu tada imaju v_4 i v_6, a vrh v_3 ima v_5 kao posredno dijete. Ostali vrhovi nemaju posredne djece. Funkcija f^2 će zatim svakom vrhu pridružiti uređeni par po matrici M'(G)^2.

$$
M'(G)^2 = \begin{bmatrix} 0 & 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}
\qquad
\begin{aligned}
f^2(v_1) &= (0,2) \\
f^2(v_2) &= (0,2) \\
f^2(v_3) &= (0,1) \\
f^2(v_4) &= (2,0) \\
f^2(v_5) &= (1,0) \\
f^2(v_6) &= (2,0)
\end{aligned}
$$

Postupak potenciranja matrice M'(G) se nastavlja sve dok se ne dobije nul-matrica. Nul-matrica se u nekim slučajevima ne bi dobila potenciranjem matrice M(G), zbog toga su se i postavljale nule na dijagonalama. Nastavljanjem ovog postupka dolazimo do matrice M'(G)^3.

$$
M'(G)^3 = \begin{bmatrix} 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}
\qquad
\begin{aligned}
f^3(v_1) &= (0,1) \\
f^3(v_2) &= (0,1) \\
f^3(v_3) &= (0,0) \\
f^3(v_4) &= (0,0) \\
f^3(v_5) &= (2,0) \\
f^3(v_6) &= (0,0)
\end{aligned}
$$

Nakon što smo potenciranjem matrice M'(G) dobili nul-matricu, onda ćemo definirati funkciju F koja će vrhu vi pridružiti uređenu trojku (ri, di, ci) gdje ri i di predstavljaju ukupan broj roditelja, odnosno djece vrha vi, dok je ci broj ciklusa vrha vi.

$$F(v_i) = (\sum_{k=1}^{m-1} r_i^k, \sum_{k=1}^{m-1} d_i^k, c_i)$$
$$m = \min\{n \in N : M'(G)^n = [0]\} \qquad (7)$$
$$c_i = a_{i,i}, M(G) = [a_{i,j}]$$

Ako poredamo sve vrijednosti funkcija fi za svaki vrh usmjerenog grafa G dobit ćemo tablicu 3.1.

	f1	f2	f3	F
v1	(0,1)	(0,2)	(0,1)	(0,4,0)
v2	(0,1)	(0,2)	(0,1)	(0,4,0)
v3	(2,2)	(0,1)	(0,0)	(2,3,1)
v4	(1,1)	(2,0)	(0,0)	(3,1,0)
v5	(1,0)	(1,0)	(2,0)	(4,0,0)
v6	(1,0)	(2,0)	(0,0)	(3,0,0)

Tablica 3.1 Vrhovi i vrijednosti funkcija f_i

Važniji će biti oni vrhovi koji imaju manji broj roditelja. Ako dva vrha imaju jednak broj roditelja, onda će važniji biti onaj vrh koji ima veći broj djece. U slučaju da dva vrha imaju jednak broj roditelja i djece, važniji će biti onaj koji ima veći broj ciklusa. Po tom načelu vrhovi v1 i v2 su najvažniji i imaju isti koeficijent važnosti. Sljedeći vrh po važnosti je v3. vrhovi v4 i v6 imaju jednak ukupan broj roditelja, ali je ipak vrh v4 važniji jer ima jedno dijete. Ako vrijednosti funkcije F za svaki vrh usmjerenog grafa G sortiramo silazno po ovom pravilu, dobit ćemo niz:

(4,0,0) , (3,0,0) , (3,1,0) , (2,3,1), (0,4,0)

Ovaj niz ima 5 elemenata i dijeljenjem rednog broja elementa niza s ukupnim brojem elemenata u nizu dobit ćemo faktor vrijednosti za svaki niz. Najmanji faktor vrijednosti ima vrh v5 i iznosi $\frac{1}{5}$ dok vrhovi v1 i v2 imaju faktor vrijednosti 1, koji je ujedno i maksimalni faktor vrijednosti.

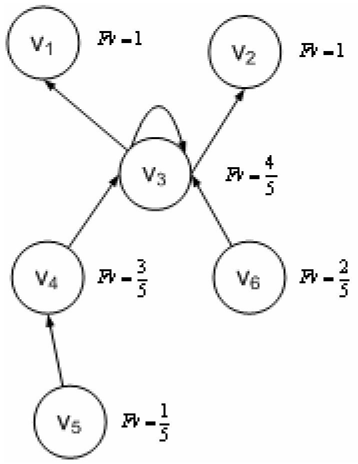

Slika 3.3 Faktor važnosti vrhova grafa G

3.2 Faktor važnosti veza

Nakon što su se odredili faktori vrijednosti vrhova usmjerenog grafa, onda će se faktori vrijednosti lukova odrediti tako što će se za svaki luk koji povezuje dva vrha uzeti srednja vrijednost faktora vrijednosti ta dva vrha. Na slici 3.4 će tako lukovi koji završavaju u vrhu v_3 imati faktore važnosti $\frac{7}{10}$ i $\frac{3}{5}$.

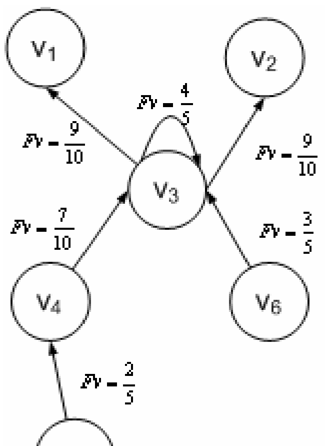

Slika 3.4 Faktor važnosti lukova grafa G

Očito postoji bijekcija koja preslikava vrhove grafa u čvorove semantičke mreže i lukove grafa u veze između dva čvora. Tom bijekcijom se prirodno preslikavaju faktori važnosti vrhova i lukova grafa u faktore važnosti čvorova i veza u semantičkoj mreži.

3.3 Faktori važnosti svojstava i vrijednosti svojstava

Određivanje faktora važnosti svojstava u okviru generičkog čvora ovisit će o faktoru važnosti samog čvora. Primjerice, ako je faktor važnosti čvora broj k, i čvor ima okvir sa ukupno m svojstava, tada će faktor važnosti svakog svojstva iznositi $\frac{k}{m}$. Analogno tome će se izračunati faktori važnosti vrijednosti svojstava u okvirima čvorova primjeraka.

4 Upotreba sustava neizrazite logike prilikom ocjenjivanja znanja

Teorija neizrazite logike je dio šire teorije neizrazitih skupova [ZADE1965]. Ona proširuje klasičnu logiku na neprekidno područje istinitih vrijednosti unutar segmenta [0, 1], omogućavajući definiranje i prijelaznih vrijednosti, a ne samo konvencionalne binarne vrijednosti. Teorija neizrazitih skupova proširuje ograničenje bivalentnih skupova tako što omogućuje glatki prijelaz među skupovima, što je osobito pogodno za opisivanje prirodnih fenomena. Kod neizrazitih skupova, element nije strogo unutar, niti je strogo izvan skupa, on također može biti djelomično u skupu. Stoga, funkcija pripadnosti za neizrazite skupove uzima vrijednosti iz intervala [0, 1] za razliku od skupa vrijednosti {0, 1} kod klasičnih skupova.

Neka je $X = \{x_1, x_2, ..., x_n\}$ skup elemenata označenih s *x*. Neizraziti skup *A* i njegova funkcija pripadnosti μ_A se definira ovako:

$$\begin{aligned} &A \subseteq X \\ &A = \{\mu_A(x_i)/x_i\} \\ &\mu_A : X \to [0,1] \end{aligned} \tag{8}$$

Neizraziti skup *A* je podskup danog temeljnog skupa *X*, čiji elementi su sadržani u *A* samo u određenom stupnju. Funkcija pripadnosti μ_A preslikava skup *X* na segment [0, 1] i govori o tome koliko mnogo je element *x* iz skupa *X* sadržan u skupu *A*.

Neizrazito zaključivanje je zasnovano na neizrazitoj logici i oponaša ljudsko zaključivanje sa približnim informacijama i neizvjesnosti prilikom stvaranja zaključaka. Ono se sastoji od nekoliko pravila, skupa činjenica i od zaključka [HARS1998]. Neizrazita produkcijska pravila povezuju premise s zaključkom, odnosno uvjete s akcijama [KLIY1995]. Njihova forma se može opisati AKO-ONDA pravilima, gdje je AKO dio pravila premisa (uvjet), a ONDA dio predstavlja zaključak (akciju). Izvršavanje neizrazitog zaključivanja se najčešće opisuje sustavom neizrazite logike prikazanog na slici 4.1 [PRIS2002].

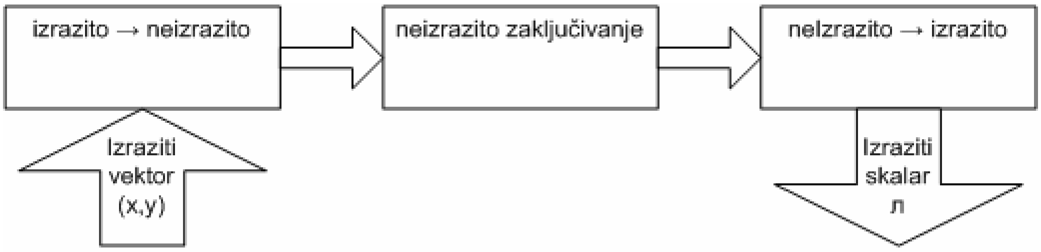

Slika 4.1 Sustav neizrazite logike

Sustav neizrazite logike je definiran trima osnovnim komponentama [KASA1998]:

1. neizrazitim ulaznim i izlaznim varijablama, definirane svojim neizrazitim vrijednostima,
2. skupom neizrazitih pravila,
3. mehanizmom neizrazitog zaključivanja.

Neizrazita pravila operiraju s neizrazitim vrijednostima kao što su, na primjer, "visoko", "hladno", "vrlo nisko" i tako dalje. Ovi neizraziti pojmovi se najčešće predstavljaju njihovim funkcijama pripadnosti. Funkcija pripadnosti pokazuje doseg do koje je neka vrijednost uključena u neizrazitom pojmu. Pogledajmo, na primjer, problem pušača i rizika oboljenja od raka. Neizrazito pravilo definira stupanj rizika oboljenja od raka ovisno o vrsti pušača. Pravilo kaže: AKO JE osoba="teški pušač" TADA rizik="velik".

Problem je kako odrediti rizik oboljenja od raka za neku drugu vrstu pušača, na primjer, za „umjerenog pušača", imajući samo gornje pravilo. Da bi se riješio gornji problem i mnogi slični problemi i složeniji problemi, potrebno je primijeniti metodu aproksimativnog zaključivanja. Metode neizrazitog zaključivanja zasnovane na neizrazitoj logici se mogu uspješno primijeniti. Neizrazito zaključivanje prima ulaze, primjenjuje neizrazita pravila i daje izlaze. Ulazi u neizraziti sustav mogu biti diskretne vrijednosti, ili neizrazita vrijednost. Izlazne vrijednosti neizrazitog sustava može biti neizrazita, na primjer, funkcija pripadnosti za danu neizrazitu vrijednost, ili diskretna vrijednost, na primjer, jednoznačna vrijednost se daje na izlaz.

Proces transformacije izlazne funkcije pripadnosti u jednoznačnu vrijednost se zove proces prijelaza iz neizrazitog u izrazito. Tajna uspjeha neizrazitih sustava je u tome što se jednostavno mogu implementirati, jednostavno održavati, što su razumljivi, robusni i jeftini.

Postupak definiranja određenog sustava neizrazite logike sastoji se od:

1. određivanja problema i izbor prikladnog sustava neizrazite logike koji najbolje odgovara zahtjevima problema. Modularni sustav se može oblikovati tako da sadrži nekoliko povezanih modula neizrazite logike. Modularni pristup, ako je primjenjiv, može uvelike olakšati oblikovanje cijelog sustava, drastično umanjiti njegovu složenost, i učiniti ga razumljivijim.
2. definiranja ulaznih i izlaznih varijabli, njihovih vrijednosti i funkcija pripadnosti.
3. učiniti razumljivim pravila neizrazitog zaključivanja.

4. izbora metode neizrazitog zaključivanja, metode pretvorbe iz izrazitog u neizrazito i obrnuto. Ako je potrebno; može se eksperimentirati sve dok se ne izabere prikladna metoda zaključivanja.
5. eksperimentiranja s prototipom sustava neizrazite logike prilagođavanjem funkcije koja povezuje ulazne i izlazne varijable, mijenjanjem funkcija pripadnosti i pravila neizrazite logike ako je potrebno, podešavanjem sustava neizrazite logike i validacijom rezultata.

Ocjenjivanje znanja učenika se može generalno opisati sustavom neizrazite logike koji kao ulaz ima izraziti vektor, a izlaz je izraziti skalar koji predstavlja ocjenu učenikova znanja.

Ulazna varijabla u sustavu neizrazite logike za određivanje ocjene znanja jest četverodimenzionalni izraziti vektor. Svaki član izrazitog vektora predstavlja postignute bodove za određeni element semantičke mreže s okvirima. Njihova pretvorba iz izrazitog u neizrazito će se vršiti pomoću odgovarajućih funkcija pripadnosti. Primjenom metode centra od maksimuma će se dobiveni stupnjevi pripadnosti Kao izlazna vrijednost sustava neizrazite logike će biti ocjena znanja.

4.1 Određivanje izrazitog vektora

Broj bodova za elemente semantičke mreže dobit će se tako što će se odrediti omjer sume faktora važnosti u bazi rješenja u odnosu na sume faktora važnosti u bazama zadatka i stručnjaka. Definirat ćemo funkcije važnosti V(*baza*, *element*) gdje parametar *baza* može biti zadatak, rješenje ili stručnjak, dok parametar *element* predstavlja skup elemenata semantičke mreže s okvirima, odnosno čvorove, veze, svojstva ili vrijednosti svojstava. Funkcija važnosti za određenu bazu i određeni element semantičke mreže s okvirima predstavlja sumu svih faktora važnosti elementa semantičke mreže. Primjerice važnost V(*zadatak*, *čvor*) predstavlja sumu faktora važnosti svih čvorova u bazi znanja.

		Baza				izraziti vektor
		Zadatak	*Rješenje*	*stručnjak*	**bodovi**	
Element	*čvor*	3.4	4.1	6.2	**0.87**	**(0.87, 0.55, 0.75, 0.90)**
	veza	4.4	5.2	8.7	**0.55**	
	svojstvo	2.9	4.4	4.9	**0.75**	
	vrijednost	3.2	5.1	5.3	**0.90**	

Tablica 4.1 Određivanje izrazitog vektora na osnovu funkcije važnosti

Prirodno se definira funkcija Bod(*element*) kao omjer razlike V(rješenje, element) – V(zadatak, element) s razlikom V(stručnjak, element) – V(zadatak, element). Time smo vrijednosti funkcije Bod ograničili na segment [0, 1].

Tablica 4.1 prikazuje primjer određivanja izrazitog vektora na osnovu važnosti elemenata semantičke mreže s okvirima u bazama zadatka, rješenja i stručnjaka. U slučaju da je razlika važnosti baze stručnjak s važnosti baze zadatka za neki element semantičke mreže, tada se bodovi za taj semantički element ne uzimaju prilikom određivanja izrazitog vektora, tj. njegova dimenzija se smanjuje za jedan.

4.2 Određivanje funkcija pripadnosti

Svakoj dimenziji izrazitog vektora pripada po jedna funkcija pripadnosti. Određivanje funkcije pripadnosti je intuitivno i bazira se na iskustvu. Pokazalo se da prilikom ocjenjivanja znanja najvažniji su bodovi za čvorove i veze, pa će njihove funkcija pripadnosti biti identične onima na slici 4.2, odnosno kontinuirano će rasti na sredini segmenta, a na krajevima će rast biti nešto sporiji.

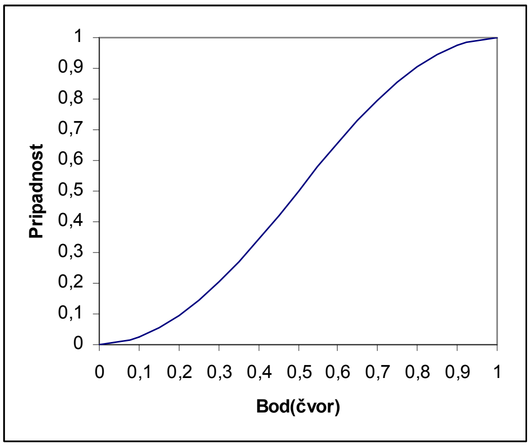

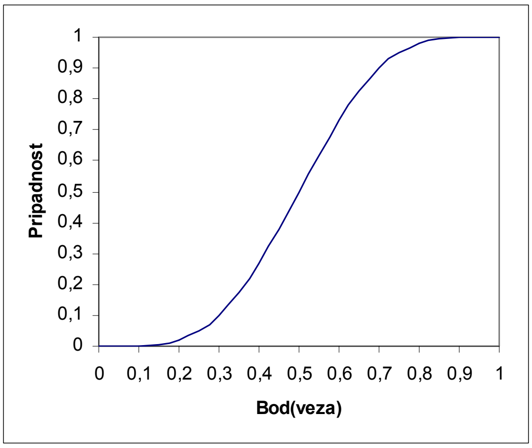

Slika 4.2 Funkcije pripadnosti za bodove čvorova i bodove veza

Svojstva i vrijednosti svojstava manje utječu na samu ocjenu, pa njihova funkcija važnosti će sporije rasti velikim dijelom segmenta kao na grafovima iz slike 4.3.

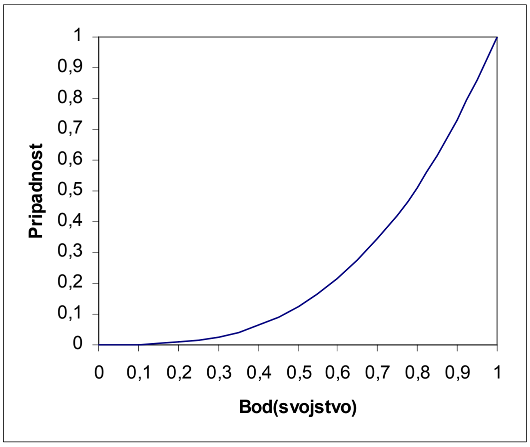

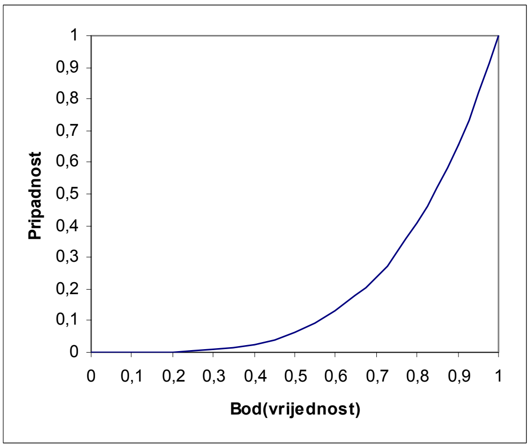

Slika 4.3 Funkcije pripadnosti za bodove svojstava i bodove vrijednosti svojstava

Ako bi pogledali vrijednosti funkcija pripadnosti za bodove elemenata semantičke mreže s okvirima danih u tablici 4.1 dobili bi neizrazite vrijednosti prikazane u tablici 4.2.

	čvor	veza	svojstvo	Vrijednost
bod	0.87	0.55	0.75	0.90
pripadnost	0.96	0.61	0.42	0.67

Tablica 4.2 Primjer neizrazitih vrijednosti dobivenih pomoću funkcije pripadnosti

4.3 Neizrazito zaključivanje

Neizrazitim zaključivanjem se neizrazite vrijednosti funkcija pripadnosti za bodove elemenata semantičke mreže s okvirima dobiva jedan neizraziti broj između 0 i 1. Kao jednostavno pravilo za određivanje tog neizrazitog broja uzeta je apsolutna vrijednost vrijednosti funkcija pripadnosti. Grafički se vrijednost neizrazitog broja može predočiti kao težište geometrijskog lika nastalog povezivanjem točaka čije su koordinate izrazita vrijednost i neizrazita vrijednost funkcije pripadnosti, kao što je pomoću grafova na slici 4.4 pronađeno težište za neizrazite vrijednosti iz primjera danog u tablici 4.2.

Neizrazite vrijednosti funkcija pripadnosti za bodove elemenata semantičke mreže s okvirima iz tablice 4.2 daje 0.665 kao neizraziti broj, koji je zapravo neizrazita ocjena znanja učenika.

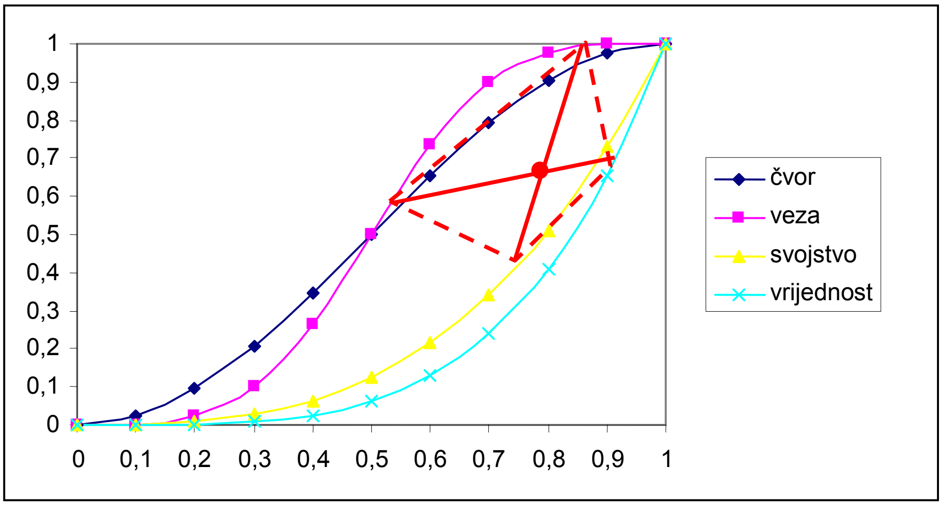

Slika 4.4 Metoda težišta za određivanje neizrazite ocjene

4.4 Određivanje izrazitog skalara

Izlazni i izraziti skalar ovog sustava neizrazite logike jest ocjena učenikovog znanja. Potrebno je odrediti funkciju koja će svakom mogućem neizrazitom broju dobivenog neizrazitim zaključivanjem dodijeliti konkretnu ocjenu. Slično kao i funkcija pripadnosti, i ova funkcija se određuje na bazi iskustva. Primjer jedne od takve funkcija je dan na slici 4.5.

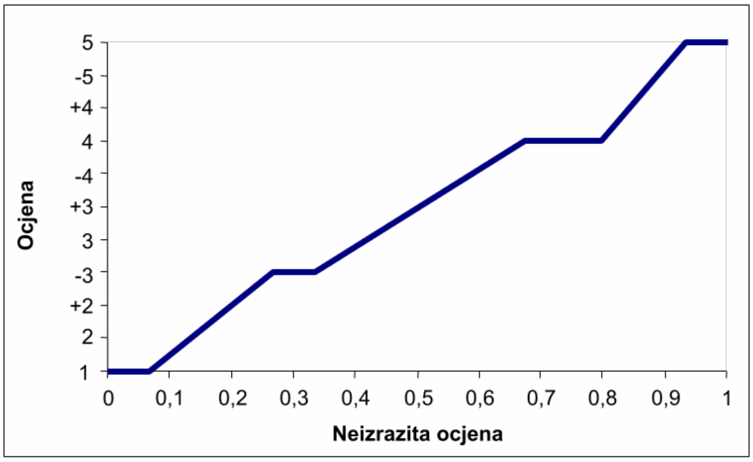

Slika 4.5 Odreživanje ocjene znanja kao funkcija neizrazite ocjene

Za neizrazitu ocjenu 0.665, ocjena znanja iznosi -4, odnosno manje od vrlo dobar. Ocjene su diskretne vrijednosti, stoga za danu neizrazitu ocjenu će se uzimati prva vrijednost ocjene koja je ispod dobivene vrijednosti neizrazite ocjene.

5 Zaključak

Inteligentni tutorski sustavi mogu imati različite tehnike za ocjenjivanje znanja. Sustav neizrazite logike je jedan od prirodnijih izbora zbog svog funkcioniranja koje je slično ljudskom procesu zaključivanja. Ocjena, kao rezultat aproksimativnog promišljanja čovjeka je teško objašnjiva na precizan i kontinuirani način. Sustavi neizrazite logike nude prikladne i fleksibilne metode zaključivanja, ali pri tome žrtvuju preciznost i točnost. Jedan od glavnih problema kod izgradnje sustava neizrazite logike je razumljivo predočavanje heurističkih neizrazitih pravila i funkcija pripadnosti. Često je potrebno usklađivati neizrazita pravila i funkcije pripadnosti kako bi se postigli zadovoljavajući rezultati. Jedan od načina rješenja ovog problema je primjena metoda strojnog učenja, neuronskih mreža i genetičkih algoritama koje bi na osnovu podataka poboljšavale neizrazita pravila i koje bi učile o funkcijama pripadnosti ako one nisu unaprijed zadane.

Ulazni izraziti vektor u sustav neizrazite logike čine bodovi postignuti tijekom testiranja znanja. Za prikaz znanja u ovom seminarskom radu se koristi tehnika semantičkih mreža s okvirima čiji su elementi čvorovi, veze među njima i okviri koji se mogu dekomponirati na svojstva i njihove vrijednosti. Svaki od tih elemenata znanja ima svoj faktor važnosti koji utječe na konačnu ocjenu. Prije su se pojedini čvorovi vrednovali jednako, a sada položaj čvora u semantičkoj mreži s okvirima definira njegov faktor važnosti. Određivanje faktora važnosti za vezu koja povezuje dva čvora jednak je srednjoj vrijednosti faktora važnosti povezanih čvorova. Čvor može i ne mora imati okvir, odnosno svojstva i vrijednosti, tako da će faktori važnosti svojstava i njihovih vrijednosti ovisit o faktoru važnosti samog čvora. Ovakvim vrednovanjem elemenata semantičke mreže s okvirima i primjenom sustava neizrazite logike ocjenjivanje testiranog znanja postaje sličnije zaključivanju koje učitelj vrši kada ocjenjuje znanje učenika. Potrebno je još jednom napomenuti kako je sustav neizrazite logike, bez obzira što se ne koriste sofisticirane tehnike za strojno učenje, lako podesiv, tako da konačna ocjena bude što bolje mjerilo testiranog znanja.

Literatura

[BRSW1996] P. Brusilovsky, E. Schwarz, G. Weber: "An intelligent tutoring system on World Wide Web", in Claude Frasson, Gilles Gauthier, & Alan Lesgold, editors, Intelligent Tutoring Systems, Vol. 1086 of Lecture Notes in Computer Science, pp. 261-269, Berlin, Germany, 1996.

[BRAN2000] Brandon Hall: "Learning Management Systems 2001: How to Choose the Right System for Your Organization", brandon-hall.com, 2000.

[STAN1997] S. Stankov: "Izomorfni model sustava kao osnova računalom poduprtog poučavanja načela vođenja", doktorska disertacija, Fakultet elektrotehnike, strojarstva i brodogradnje, Sveučilište u Splitu, Split, 1997.

[QUIL1968] M.R. Quillian: "Semantic memory", in M. Minsky (ed.):, Semantic Information Processing, MIT Press, 1968.

[ANAS1998] A. Analyti, N. Spyratos, P. Constantopoulos: "On the Semantics of a Semantic Network", Fundamenta Informaticae, Vol. 36, No. 2-3, pp. 109-144, 1998.

[STAG2000] S. Stankov, V. Glavinić, M.Rosić: "On Knowledge Representation in an Intelligent Tutoring System", in proceedings of 4th IEEE International Conference on Intelligent Engineering Systems – INES'2000, Portoroz, Slovenia: 2000, pp 17-19.

[VELJ1989] D. Veljan: "Kombinatorika s teorijom grafova", Školska knjiga, Zagreb, 1989.

[ZADE1965] L. A. Zadeh: "Fuzzy Sets", Information and Control, Vol. 8, 1965.

[HARS1998] J. W. Harris, H. Stocker: "Handbook of Mathematics and Computational Science", Springer-Verlag, New York, 1998.

[KLIY1995] G. J. Klir, B. Yuan: "Fuzzy Sets and Fuzzy Logic Theory and Applications", Prentice Hall PTR, 1995.

[PRIS2002] PRIS Project: "Fuzzy Expert System Model", Soft Computing Guidebook, 2002.

http://www.comp.nus.edu.sg/~pris/FuzzyLogic/ModelDetailed1.html

[KASA1998] N.K. Kasabov: " Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering", The MIT Press, Vol. 2, 1998.