

Mr. Vanja Bevanda

Asistent na Ekonomskom fakultetu u Mostaru

AKVIZICIJA ZNANJA

UDK/UDC 65.011.56

Pregledni rad

Primljeno/Received: 26. ožujka/March 1997.

Sažetak

U radu su prikazane aktivnosti prvog stupnja izgradnje ekspertnog sustava, organizirane kroz meta model procesa akvizicije znanja. Date su upute za konkretan rad sa ekspertom. Na osnovi tako prikazanog procesa akvizicije znanja eksperta u okviru inženjeringa znanja, utvrđene su poželjne osobine eksperta koje omogućavaju uspješan rad imženjerima znanja na izgradnji baze znanja.

Ključne riječi: akvizicija znanja, inženjering znanja, ekspertni sustavi, ekspert.

UVOD

Sastavni dio aktivnosti prvog stupnja izgradnje ekspertnog sustava jest proces akvizicije znanja. Pod tim pojmom podrazumijeva se prijenos i transformiranje ekspertize rješavanja problema iz nekog izvora znanja u program (prema B. G. Buchanan, E. H. Shortliffe, 1985). Ekspertiza kojom se ekspert bavi, a koju želimo prenijeti u program, jest kolekcija definicija, veza, specijalnih činjenica, algoritama, strategija i heuristika o uskom, specifičnom području. Ona je različita od općeg znanja o području i od zdravorazumskog znanja o svijetu.

Kognitivna analiza jest srce inženjeringa znanja. Kada smo zaključili za koje probleme ćemo graditi ekspertni sustav, tj utvrdili potrebe za njim,

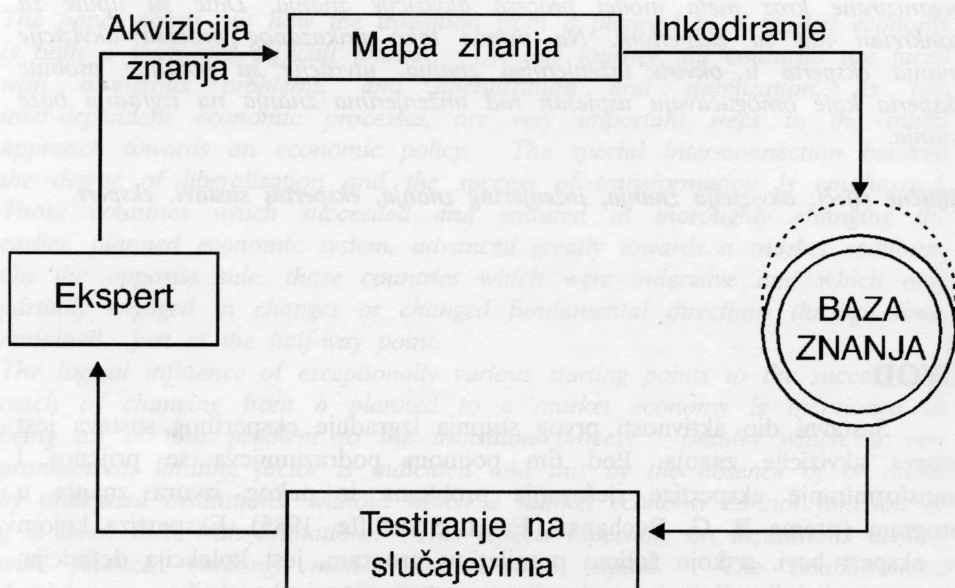
slijedi proces rada sa ekspertom (ekspertima) da bi se utvrdilo što zna i kako povezuje različite činjenice, tj kako razmišlja o problemu koji rješava.

Najzanimljivije stvari događaju se u ekspertovoj glavi. To nije moguće objasniti nekom tko samo promatra ponašanje (da je to tako, bila bi dovoljna samo analiza zadatka). Eksperti razmišljaju, formiraju hipoteze i onda postavljaju pitanja da bi ih potvrdili ili odbacili.

Kognitivna analiza je proces kojim utvrđujemo što ekspert zna i kako razmišlja o problemu. To je nesavršen proces: češće je umjetnost nego inženjering. Srećom, postoji empirijski model koji se može koristiti za prikupljanje i prikazivanje znanja koje se dobije tijekom kognitivne analize. Tada se znanje dobiveno od eksperta prenosi u bazu znanja i tada se zajedno sa ekspertom pokušavaju riješiti pojedini problemi. Kako ekspertni sustav rješava pojedine specifične slučajeve, ujedno se i sam razvija; kroz rafiniranje i usavršavanje baze znanja, sve do one točke kada i sustav radi približno dobro kao i čovjek ekspert.

Slika 1.

Proces inženjeringa znanja



Kada se kreiraju mali sustavi, inženjeri znanja jednostavno inkodiraju neka znanja i odmah nastoje usavršavati taj sustav kroz proces pokušaja i pogrešaka. Takav način rada moguće je primijeniti kod malih sustava. Ako

ekspert posjeduje mnogo znanja, bolje je pokušati razviti dobar pregled znanja prije nego što se počne pisati kod.

Slika 1. sadrži prikaz inženjeringa znanja. Da bi se razvio sustav baziran na znanju, potrebno je prikupiti i predstaviti znanje. Netko mora već posjedovati to znanje, izvor znanja (to može biti jedan ekspert ili više njih, literatura, baze podataka i sl).

Zatim, na neki način to znanje mora se crpiti i formalizirati. Ta formalna reprezentacija znanja poznata je kao mapa znanja (knowledge map). Kada se razvije zadovoljavajuća mapa znanja, potrebno ju je transformirati u formu pogodnu za računala. Cjelokupan proces crpljenja znanja poznat je kao akvizicija znanja.

Prvi produkt akvizicije znanja jest mapa znanja koja sadrži pregled znanja eksperta. Informacije iz nje se koriste za izgradnju baze znanja koja će se koristiti pri radu. Jednom kada se inicijalna baza izgradi, moguće ju je testirati i dalje razvijati na slučajevima. U ovisnosti kako sustav radi, moguće ju je modificirati, usavršavati, mijenjati sve dok sustav ne počne težiti prevelikoj determiniranosti ekspertize. Cjelokupni prikazani proces naziva se inženjeringom znanja.

Potrebno je napomenuti da različiti autori, različito imenuju faze procesa akvizicije znanja, no sadržaj je isti. Tako B. G. Buchanan i E. H. Shortliffe, 1984., proces akvizicije promatraju kroz tri stupnja:

1. - konceptualizacija baze znanja (definiranje problema i izbor konceptualnog ustrojstva)
2. - konstruiranje baze znanja u okviru konceptualnog ustrojstva
3. - usavršavanje baze znanja da bi odgovarala zahtijevanim osobinama.

F. Hayes-Roth, D. A. Waterman i D. B. Lenut (prema A. Barr, P. R. Cohen; E. A. Feigenbaum, 1989) razlikuju čak pet faza procesa akvizicije znanja:

1. - identificiranje - određivanje osobina problema, izbor problema pogodnog za rješavanje ekspertnim sustavom,
2. - konceptualiziranje - identificiranje i objašnjenje pojmova i relacija potrebnih za opis rješavanja problema i znanja,
3. - formalizacija, oblikovanje strukture pomoću koje ćemo organizirati znanje
4. - implementiranje - formuliranje pravila za pretvorbu znanja
5. - provjeravanje - vrednovanje pravila kojim se organizira znanje.

Aktivnosti koje se sprovode kroz ove stupnjeve su identične već objašnjenim, jer je razmatran inženjering znanja. Postoje i drugi modeli za transfer ekspertize osim inženjeringa znanja .

Moguće je programirati svaki novi program u LISP-u (ili nekom drugom programskom jeziku). To se naziva još i "custom crafting" ili proceduralno umetanje (usađivanje) znanja. Taj metod je mnogo sporiji i rezultati su manje fleksibilni nego oni dobiveni inženjeringom znanja.

Drugi modeli su isključili inženjera znanja i bazirani su na izravnom dijalogu eksperta i programa (baze znanja). Tendencija je eliminirati inženjera znanja. Alati kao što je npr. TEIRESIAS (korišteni za konstruiranje poznatog Mycin-a) sadrže modele kojim ekspert može graditi i usavršavati bazu znanja bez pomoći inženjera znanja. Za jednostavnije domene takvi alati su dovoljni za eksperte, uz malo treninga. Kako kompleksnost sustava raste, suma vremena eksperta utrošena na razvoj enormno raste; pa se pokazala neophodnost prisutnosti inženjera znanja u ulozi prevoditelja.

Postoje modeli akvizicije znanja koji nastoje ostaviti izvan transformacijskog procesa i eksperte i inženjere znanja (reading modeli). Takvi su čitanje i indukcija. Ovdje se razvijaju alati za pažljivo iščitavanje literature, u potrazi za činjenicama i pravilima koji će biti uključeni u bazu znanja. Pokazalo se da je potrebno mnogo više vremena za pripremanje članaka za ove svrhe, no što bi se utrošilo za intervjuiranje eksperta.

Analizom ovih modela akvizicije znanja uočljiva je njihova težnja eliminirati ili/i svesti na manju mjeru komunikacijske probleme, od kojih pati proces akvizicije. Po definiciji, inženjer znanja ima mnogo manje znanja o domeni od eksperta; i to je izvor poteškoća akvizicije (počevši od neadekvatnog rječnika pojmova, pa do nerazumijevanja složenih situacija odlučivanja od strane inženjera znanja). Na današnjem stupnju razvoja ekspertnih sustava, modela i alata akvizicije; još uvijek je najviše u uporabi inženjering znanja, koji će u radu dalje biti razmatran.

Sljedeće poglavlje bavit će se općim konvencijama, kojim se podržava i prikazuje ono što čovjek, ekspert zna; kako je došao do tog znanja i kako to aranžirati u mapu znanja. Nije posvećivana pažnja rječniku i notacijama koji se koriste pri kreiranju baze znanja, jer oni ovise o konkretnom problemu.

1. HIJERARHIJSKA STRUKTURA MEMORIJE

Da bismo razumjeli znanje eksperta, potrebno je razmotriti na koji način je ono organizirano u memoriji čovjeka. Mnoga istraživanja su pokazala da se radi o hijerarhijskoj strukturi, tj većina ljudi drže informacije na što je moguće višoj apstraktnoj razini. Taj se koncept može objasniti primjerom životinja i njihovom objekt-atribut-vrijednost hijerarhijom. Mi, umjesto da pamtimo da kanarinac i golub lete, jednostavno se sjetimo

da sve ptice (sa izuzecima) lete, polažu jaja i sl; čak ih još generalnije svrstavamo u kategorije životinja koje se hrane i dišu i sl. I ako nas pitaju, diše li kanarinac, sjetimo se da je on ptica, da su ptice životinje i da sve životinje jedu i dišu, pa prema tome i kanarinac diše; i pri tom nismo imali memoriranu informaciju da kanarinac diše.

Ovakav hijerarhijski pristup pohranjivanja informacija objašnjava mnoge primijećene činjenice o tome kako ljudi pamte i drže problem u memoriji, i upućuje na činjenicu da i čovjek ekspert organizira svoje znanje na sličan način. On razvija strukturu sa različitim objektima i različitim stupnjevima apstrakcije, udružuje attribute sa najvišim stupnjem apstrakcije koja mu se čini praktičnom. Izuzetke čine, stvari pohranjene kao konkretni objekti, a tiču se pojedinačnih ljudi, slučajeva i stvari.

Neki eksperti će moći samostalno crtati hijerarhijski dijagram različitih koncepata vlastite domene. Većina njih, posjeduje takve strukture, ali nesvjesno; njihova ekspertiza sastoji se u sposobnosti da riješe problem, ali ne i da objasne kako su to učinili. Prvi korak akvizicije znanja, tada će pomoći ekspertu da izrazi takvu strukturu.

Psiholozi koriste izraz "chunking" koji je neprevodiv na naš jezik, a kojim opisuju proces kojim ljudi grupiraju objekte na istoj razini u višu grupu; apstraktniju grupu. Ljudska memorija sačinjava grupu različitih hijerarhija, gdje se svaka odnosi na različitu domenu (područje).

Dok smo mladi počinjemo sticati specifične činjenice o svijetu. Kako rastemo hijerarhije znanja se konstantno reorganiziraju i rekompilira se znanje, da bi prihvatili nove činjenice. Ako se znanje ne reorganizira, bit ćemo onemogućeni u traženju puta do nekih specifičnih činjenica (ili većine njih) koje smo već stekli.

Inženjeru znanja problemi nastaju kada ekspert počne koristiti apstraktne hijerarhije koje su konceptualne prirode. Npr. većina eksperata u području tehnike koriste pojam "akceleracije" bez razmišljanja o kompleksnosti te apstrakcije. Oni su pri memoriranju napravili apstrakciju od koncepata i operacija i spojili ga u jedinstven pojam koji se odnosi na mnoga mjerenja i kalkuliranja (udaljenosti, vremena, brzine). Ili u slučaju statističara, koji često upotrebljavaju identičan koncept govoreći da je neki broj "signifikantan".

Uporaba te riječi sadržava uporabu mjerenja i kalkuliranja, i eksperti statističari je upotrebljavaju ne razmišljajući o njezinom tehničkom značenju (i izračunavanju koje je pri tom potrebno izvršiti).

U ovom slučaju, dobar početak rada inženjera znanja jest pitati eksperta da definiira taj apstraktni pojam na nižoj razini, upotrebljavajući obično 3-4 "chunk-a" tj manje apstraktna pojma; i spuštati se na niže hijerarhijske stupnjeve. Na takav način se formira hijerarhijski dijagram pojmova koje je ekspert iskustvom memorirao.

Na ovaj način postaje razumljivo kako eksperti savladavaju kompleksnost problema kojima se bave u svom poslu. Oni ulančavaju činjenice na sve veći stupanj apstraktnosti (sa većim stupnjem općenitosti); i


tako stvarnost svode na 3-4 opće varijable. Onda su osposobljeni da brzo analiziraju uzroke problema i dolaze do strategije rješavanja problema.

Glavni izazov inženjeru znanja jest upravo to odmotavanje lanaca strukture znanja koje posjeduje ekspert. Tijekom razgovora sa ekspertom, moguće je da postane jasnim da se izvor strukture znanja o problemu nalazi u više apstraktnih, (deep) teorija (slika 2.); ili u još gorem slučaju u samo jednoj općoj teoriji.

Npr., jedan službenik u nekoj banci, memorira veliki broj različitih faktora iz raznih područja kao što su: osobine financijskih kompanija koje žele posuditi novac, kako se upravlja tim kompanijama, kakvi su stavovi uposlenih (kultura tvrtke), kakva je konkurencija toj tvrtki i sl., što znači da mora kombinirati različite opće teorije počevši od računovodstva, makro-ekonomije, psihologije i teorije menadžmenta.

Slika 2.

Domensko znanje izvedeno iz više od jedne opće teorije



Inženjering znanja sadrži definiranje multidimenzionalne mreže koncepata i heuristika, koje je ekspert stjecao i prepravljao tijekom mnogih godina. Raspetljavanje zamršenog klupka povezanih (čvrsto agregiranih) informacija i njihovo predstavljanje kroz mapu znanja je doista izazov i umjetnost.

Većina inženjera često razmišljaju primjenjujući analogiju na domeni sa kojom su već bliski i koju razumiju (s čime su već nekada radili). To ih onemogućava da stvarno razumiju eksperta i njegov domen; te da u njegovom rasčlanjivanju dospiju do općih teorija. To objašnjava činjenicu zašto su mladi ljudi (koji tek počinju raditi u inženjeringu znanja) uspješniji u obavljanju procesa akvizicije znanja.

Oni su u stanju razlikovati veliki broj različitih "deep" teorija, i u boljoj su poziciji da pronađu neku teoriju blisku onom što ekspert zna i radi. Drugim riječima, njima je potrebno manje stvari da "zaborave"; iskustvom nisu stvorili svoje lance apstraktnih pojmova i nisu u mogućnosti praviti analogije sa sličnim riješenim problemima.

2. META MODEL PROCESA AKVIZICIJE ZNANJA

2.1. MODEL OBJEKT - ATRIBUT -VRIJEDNOST

Bilo koja stvar (pojam) koja može biti odvojena i razlikovana od druge stvari, može biti identificirana kao objekt. Ti objekti se mogu grupirati na viši, apstraktniji stupanj sličnih objekata i tada govorimo o klasi objekata (npr. ptica je klasa objekata koja uključuje tisuće specifičnih vrsta ptica (objekata). Da bi identificirali klasu objekata koji uključuju ili isključuju specifične objekte u klasu. potrebno je posjedovati neki kriterij za njihovo klasificiranje.

Svaka specifična stvar je zapravo instanca različitih klasa objekata. Očigledno, svaka specifična stvar je manje ili više različita od druge stvari. Ako prepoznamo da grupa stvari ima nešto zajedničko, to je zato što sve dijele zajednički set karakteristika. Ime objekta jest riječ koju primjenjujemo na set karakteristika koje dijele sa svim instancama koje konstituiraju taj objekt.

Zajednička karakteristika stvari koje čine objekt, postaje atribut tog objekta. Atribut je ime dato apstrakciji istih karakteristika, koja svaka instanca objekta posjeduje. Svaki od atributa objekta je neovisan od svakog drugog.

Specifičan set vrijednosti je udružen sa svakim atributom. Klasa objekata može imati udružene specifične vrijednosti, ali pravilo je, da se udružuju setovi vrijednosti sa atributima klase objekta.

Npr. riječ "ptica" može biti klasa objekta koja predstavlja sve specifične instance ptica. Neke od zajedničkih osobina ptica su da pjevaju, lete, legu jaja i sl. Svaka od osobina se može identificirati kao atribut

objekta "ptica". Ptice, kao klasa, ima i neke posebne atribute i vrijednosti (posebne vrste). Svaki od atributa može imati specifične vrijednosti (stvarne instance apstrakcije, ptica). Dalje je moguće grananje, da atributi apstrakcije postaju sami objekti sa svojim posebnim atributima i vrijednostima, u ovisnosti kako detaljan model gradimo. Tako relacije i veze između različitih klasa objekata mogu biti vrlo kompleksne. Model "objekt - atribut - vrijednost" predstavlja osnovu za formiranje mape znanja. Problem nastaje kada se počne savladavati kompleksnost tih veza i njezino reprezentiranje. Tada se u literaturi susrećemo sa različitim tehnikama reprezentiranja znanja. Uopće, te veze se mogu prikazati dvjema hijerarhijama: hijerarhije klasifikacija i kompleksno povezane hijerarhije (networks).

1. - Hijerarhije klasifikacija

Kod ovog načina prikazivanja znanja, svaki stupanj hijerarhije sadrži apstraktniji način grupiranja objekata opisanih na nižem stupnju. Apstraktniji pojam, na višoj razini obično se zove superset, a onaj na nižoj (specifičnoj) razini podset (subset). Veze između njih su tipa "jeste" (engl. IS-A). (Npr. ptica je tip životinje i sl.).

2. - Kompleksno povezane hijerarhije

Često se nazivaju mrežama (networks). Kod nje neke hijerarhije koriste mnogo različitih veza (koje nisu sve tipa "jeste") da bi opisale specifične veze između objekata. Takva ustrojstva obično se predstavljaju mrežama i onda mogu postati vrlo kompleksna; kompleksnija i konfuznija od prvog načina prikazivanja.

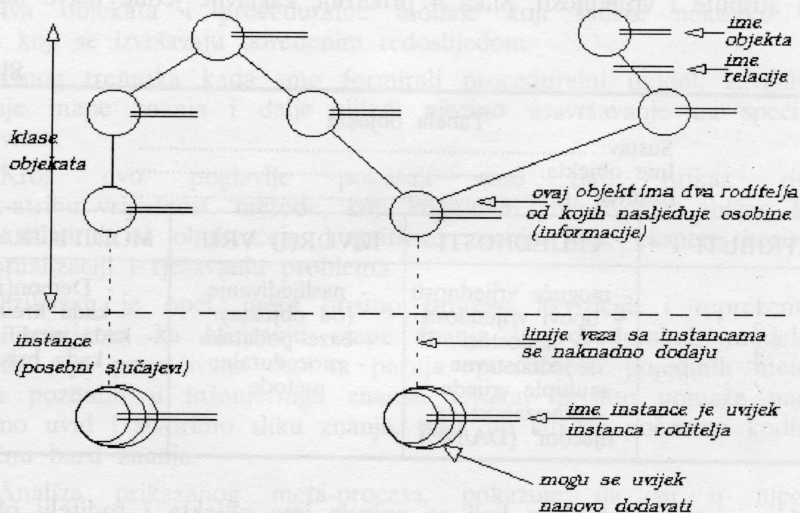
Preporučuje se počinjanje bilo kojeg projekta pokušajem predstavljanja znanja eksperta putem hijerarhija objekata (superseta i podsetova) i prelazak na mreže jedino u slučaju kada ovaj jednostavniji pristup nije u stanju obuhvatiti značajne aspekte ekspertovog znanja.

Prikazana ustrojstva su statična; međutim većina objekata prolazi kroz neku vrstu "životnog ciklusa", kroz određene životne stupnjeve, stadije. Ako objekt mijenja stanje, to se obično predstavlja kao atributi objekta sa svojim vrijednostima. Tada klasa objekata ima atribut "stanje" i njegova vrijednost će odrediti vrijednost drugih atributa koji se odnose na to stanje. Postoje i neke osnovne konvencije prikazivanja klasa objekata (slika 3.).

Klase objekata se prikazuju kružnicama, a instance osjenčenim kružnicama da bi naznačili da se mogu uvijek nanovo dodavati. Relacije (veze) između klasa su prikazane jednostrukom linijom a veze između klasa objekata i instanci točkastim linijama. Često se za razdvajanje pojmova klase objekata i njezinih instanci koriste različiti pojmovi. Bez obzira kako ih pojedini inženjeri znanja zvali; svi razlikuju setove atributa bez specifične vrijednosti (kod nas klase objekata) i specifične vrijednosti udružene sa atributima tijekom konzultiranja sa ekspertom (i te parove atribut-vrijednost, pohranjuju u radnu memoriju, a ne u mapu znanja).

Slika 3.

Prikaz mreže objekata



Ako se radi na hijerarhijama klasifikacija primjenjuje se identična notacija, sa naznakom da su onda sve relacije tipa "IS-A". Ako se kreira mreža moraju se označavati imena relacija tj odnosa između objekata.

U izgradnji ustrojstava znanja moguće je razvijati nekoliko prividno neovisnih hijerarhija i onda ih povezivati, gdje ta ustrojstva imaju zajednički korijen (objekt); no to je više stvar programiranja, a ne kreiranja mape znanja.

2.2. KREIRANJE MAPE ZNANJA

Na ovaj način smo opisali na koji način početi kreiranje mape znanja i objasnili osnovnu logiku i notaciju koja se pri tom koristi. U literaturi je, do sada opisana procedura poznata kao prvi stupanj formiranja mape znanja, tj kao 1. Opisivanje ustrojstva. Slijedeći koraci su:

2. Opisivanje klasa objekata
3. Opis pravila i specificiranje proceduralnog modela
4. Razvijanje mape znanja

2. Opis klase objekata

Kada je razvijena hijerarhija ili mreža, jedna ili više njih, pristupa se detaljnom opisu svakog objekta. Za tu priliku se formiraju tabele koje opisuju atribute i vrijednosti. Slika 4 prikazuje zaglavlje jedne takve tabele:

Slika 4.

Tabela objekta			
Sustav:			
Ime objekta:			
Roditelj (i):			
ATRIBUTI	VRIJEDNOSTI	IZVOR(I) VRIJ.	MODIFICIRANJE
1.	- moguće vrijednosti	- naslijeđivanje (od objekta)	- Demon(i)
2.	- tipovi vrijednosti	- baze podataka	- kada kreirati
3.	- nedostaci	- proceduralne metode	- kada modificirati
.	- jednostavne multiple vrijedn.		- kada brisati
.	- povezanost sa "djecom" (DA/NE)		

U njoj postoji blok u koji se upisuje ime objekta i roditelji objekta. Ispod se nalaze redovi ili slotovi. Svaki slot je podijeljen na četiri stupca (facet), svaki za specifičan tip informacija. U prvi stupac unosi se ime atributa, u drugi informacije o njegovim mogućim vrijednostima, u treći se unose podaci kako će sustav dobijati vrijednosti atributa i u stupac 4 se unose bilo koje informacije o tome što sustav može činiti ako se stvarno kreira instanca i dobije vrijednost svakog pojedinačnog atributa tj indiciraju se moguće veze između atributa i vrijednosti udruženih sa različitim objektima.

Rad se nastavlja opisom objekata kroz ovakve tabele i ponovnim vraćanjem na dijagram ustrojstva, dok se ne postigne zadovoljavajući prikaz ekspertovog znanja. Svaki objekt u mreži, treba imati pridruženu tabelu objekta, koja definira atribute, vrijednosti, i metode dobivanja i modificiranja tih vrijednosti.

3. Opisivanje pravila i određivanje proceduralnog modela

Nakon što su opisani objekti i atributi u bazi znanja, stvoreni su uvjeti za bilježenje heuristika koje ekspert koristi razmišljajući o svom znanju. U stvari, ekspertova objekt-atribut mreža ili model domene sličan je bazi podataka, dijagrami objekata su u inženjeringu znanja ekvivalent strukturi baze podataka (dijagrami entiteta i veza; entity-relationship diagram).

Umjesto modela domene koji opisuje objekte i atribute iz ekspertovog svijeta, obično se kreira proceduralni model koji sadrži setove heuristika koje eksperti koriste pri rješavanju problema. Pri strukturiranju sustava baziranih na pravilima (rule systems), proceduralni modeli se

nazivaju "odnosno stablo" (context tree). Proceduralni model je ekvivalentan modelu sa visokostrukturiranim dijagramom podataka (algoritama).

Najjednostavniji sustavi, posjeduju bazu znanja koja sadrži samo jedan set pravila. Kompleksniji sustavi, domensko znanje organiziraju kroz ustrojstva objekata i proceduralne modele koji sadrže nekoliko setova pravila koji se izvršavaju određenim redoslijedom.

Onog trenutka kada smo formirali proceduralni model, završili smo kreiranje mape znanja i dalje slijedi njezino usavršavanje na specifičnim slučajevima.

Kroz ovo poglavlje pokušali smo dati prikaz rječnika "objekt-atribut-vrijednost, metode, koji kognitivni znanstvenici obično koriste kada analiziraju i obuhvaćaju kognitivno znanje koje ekspert koristi pri konceptualizaciji i rješavanju problema.

Prikazan je opći, meta pristup procesu akvizicije i reprezentiranja znanja, usmjeren ka kreiranju mape znanja i proceduralnih modela što znači da nije posvećivana osobita pažnja specifičnosti pojedinih metoda i tehnika poznatih u inženjeringu znanja. Ovakav pristup pomaže nam da dobijemo uvid i stvorimo sliku znanja, prije no što ga počnemo kodirati u specifičnu bazu znanja.

Analiza prikazanog meta-procesa, pokazuje da su u njegovom odvijanju u potpunosti poštivane faze procesa akvizicije znanja kreirane od grupe autora (F. Hayes-Roth, D. A. Waterman i D. B. Lenut): identifikiranje, konceptualizacija, formalizacija, implementiranje i provjeravanje).

Prikazano je ono što je opće i zajedničko poznatim metodama i tehnikama akvizicije znanja.

3. RAD SA EKSPERTOM

Crpljenje znanja jest kompleksan proces. Najjednostavnije rečeno, on zahtijeva prikupljanje znanja koje će biti uključeno u ekspertni sustav. U širem smislu, on obuhvaća cjelokupni proces inženjeringa znanja, uključujući intervjuiranje eksperta, razvoj mape znanja i njezino pretvaranje u bazu znanja, i onda testiranje i revidiranje tog znanja zajedno sa ekspertom i korisnicima. Preduvjet odvijanja tog procesa jest proces dobivanja informacija od eksperta. Da bi olakšali njegovo izvođenje neki inženjeri znanja stavljaju se u ulogu eksperta; drugi ispituju jednog, a neki više eksperata. Načini dobivanja informacija od eksperta su različiti, i globalno se mogu, u okviru inženjering znanja, podijeliti na dvije grupe, a to su: ispitivanje eksperata (intervjui) i promatranje eksperata na djelu.

1. - Ispitivanje eksperta podrazumijeva da se od eksperta traži da se prisjeti što je činio ili da zamisli kako bi postupio pri rješavanju određenog problema.

2. - Promatranje eksperta pri njegovom radu, usmjereno je na utvrđivanje aktualnog ponašanja eksperta, dok rješava stvarni ili/i simulirani slučaj. Ovdje je vrlo značajno odrediti problem koji će se promatrati, a kada je to utvrđeno, zahtijeva se od eksperta glasno razmišljanje i obrazlaganje primijenjenih postupaka i razloga za svoje procjene i odluke. Moguće je takvo ponašanje i snimati, pa onda ekspert naknadno pruža objašnjenja.

U ovisnosti da li je slučaj stvaran ili simuliran, je li objašnjenje eksperta trenutačno ili naknadno moguće je primijeniti četiri tehnike crpljenja znanja na ovaj način. Čak je ovakva tehnika idealna za rješavanje problema prezauzetosti eksperta (nedostatka vremena za "seanse" intervjua), no i dalje ostaje problem kada i koje uzorke ponašanja treba promatrati.

Većina ekspertnih sustava danas je izgrađeno ispitivanjem eksperata; i imajući u vidu ciljeve rada, a među njima i utvrđivanje potrebnih (i poželjnih) osobina eksperta, od značaja je istražiti proceduru rada sa ekspertom kroz intervjuiranje.

Intervjuiranje je opet osnov uspješnog odvijanja procesa akvizicije i postoji mnogo načina da se ono ostvari. Različite škole (naročito psihološke) pružaju različite tehnike (alate) koje potpomažu takvo ispitivanje. Navest ćemo samo neke od njih: Repertoarske rešetke, tehnike kritičnih događaja, tehnike uparivanja karakteristika i odluka, razlikovanje ciljeva, analiza odlučivanja.

Repertoarske rešetke

Prema shvaćanju G. A. Kelly (prema A. Fulgosi, 1981.g.) koji je razvio ovu tehniku na području psihologije ličnosti; svaka osoba na svoj, specifičan način percipira procese i događaje, pri tom izgrađuje vlastite spoznaje o njima; izgrađuje hipoteze i provjerava ih na vlastitom iskustvu. Naslanjajući se na ovakav teorijski predložak, kreiraju se "repertoarske rešetke" sačinjene od elemenata i konstrukcija osobina koje svaki od elemenata posjeduje. Elementi se ocjenjuju, opisuju s obzirom na stupanj u kojem posjeduju te osobine, i tu se obično koriste skale procjenjivanja.

Da bi se tehnika mogla uspješno primijeniti potrebno je jasno odrediti i definirati problem. Stalnim procjenjivanjem elemenata (i njihovih osobina), izbacivanjem suvišnih, uvođenjem novih odvija se proces kojem je cilj vjerodostojan prikaz ekspertovog znanja u obliku rešetki sa ključnim mjestima (čvorovima). Za analiziranje ovako dobivenih podataka obično se upotrebljavaju faktorska analiza i/ili klasterska analiza.

Prva, faktorska analiza (koja je vrlo skupa i zahtijevna) omogućava proučavanje strukture skupa osobina, s obzirom na to kako je njihova varijanca objašnjena skupom faktora; dok klasterska analiza, dopušta grupiranje elemenata na osnovi njihovih međusobnih odnosa (interkoleracije, sličnosti i sl.) u podskupove tj klastere.

Tehnika kritičnih događaja

Potiče iz područja primijenjene psihologije, i u njoj se od eksperta traži da potanko opiše značajne i zanimljive primjene iz vlastitog iskustva, a

naročito one korake koji su rezultirali uspješnim rješavanjem problema. Kod ove tehnike treba imati na umu da se onda radi o netipičnim uzorcima osnovnog skupa slučajeva (primjera) i da je takve informacije potrebno oprezno koristiti. Ona je pogodna za sticanje znanja o činjenicama i nekim heuristikama.

Tehnika uparivanja karakteristika i odluka

Od eksperta se traži da navede skup značajnih osobina konkretne problemske situacije i skup mogućih, rezultirajućih odluka i zatim se grupiraju u parove; osobine situacija sa odlukama. Na taj način pravila se ne izriču verbalno, nego se podrazumijevaju u formiranim parovima. U nedostatku sposobnosti verbalnog opisivanja što zna, ekspertu je ova tehnika mnogo bliža od ostalih.

Razlikovanje ciljeva

Utvrđeno je da se pri rješavanju problema, stvara čitavo ustrojstvo, posrednih i neposrednih ciljeva. Identificiranjem takve strukture ciljeva, sa utvrđivanjem razloga za njihovo međusobno razlikovanje, moguće je izgraditi strukturirani model znanja o ekspertu.

Analiza odlučivanja

Analiza odlučivanja je tehnika crpljenja znanja kojom se identificira problem odlučivanja, ciljevi i njihova moguća stanja, posljedice mogućih akcija (njihove vjerojatnoće) i kriteriji odlučivanja, odnosno utvrđuje cjelokupni proces odlučivanja koji ekspert izvršava. Pri tom se koriste stabla i tabele odlučivanja, na osnovi kojih se pokušavaju utvrditi neophodna znanja.

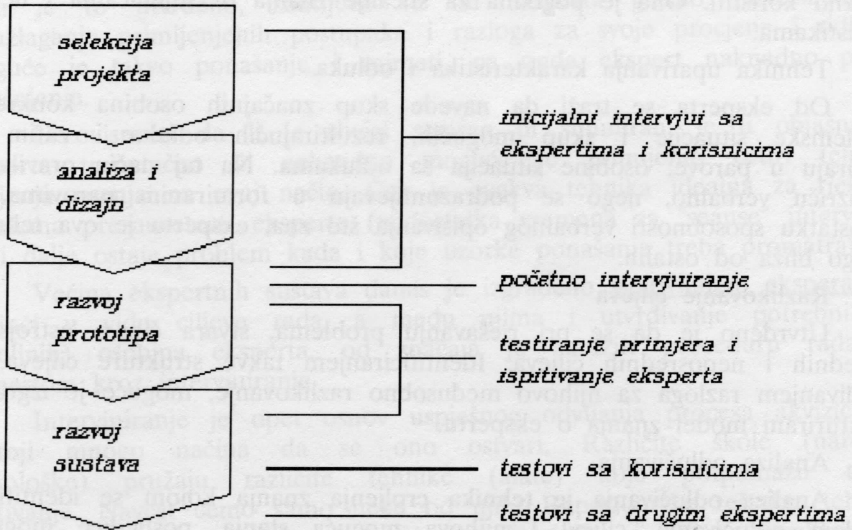
Ovim kratkim prikazom metoda i tehnika akvizicije znanja i njegovom analizom postaje jasno da u literaturi ne postoji točna diferencijacija klasifikacija tih metoda. Kod pojedinih autora pod akvizicijom znanja se obuhvaća i crpljenje znanja od eksperta i prikaz (reprezentiranje) tog znanja, (npr. kod P. Harmon-a i B. Sawyer-a, 1990. g.), dok kod drugih su to dva odvojena, slijedna procesa.

Ne želeći ispitivati razloge za i protiv pojedinog pristupa, primijetiti ćemo da navedene metode (i tehnike koje ih podržavaju) pružaju odgovor na pitanje: "Što pitati eksperta?", tj. na koji način mu olakšati "iskazivanje neizrecivog znanja"; kako prikazati dobivene odgovore.

Cjelovitiji odgovor, tj. odgovore i na pitanja tipa "kako pitati?, kada pitati?, kako najbolje iskoristiti dobivene odgovore?", pokušat ćemo dobiti razmatranjem šireg uputstva za rad sa ekspertom, koji ne prejudicira pojedinu metodu (tehniku) za rad. Sljedeće uputstvo sastoji se od slijednog izvođenja četiri koraka. (slika 5.):

Slika 5.

Jedan od mogućih prikaza procesa akvizicije znanja



(Izvor: P. Harmon i B. Sawyer: "Creating Expert Systems for Bussiness and Industry")

- korak 1: Inicijalna analiza zadatka i selekcija eksperta
- korak 2: Priprema za intervjuiranje
- korak 3: "Početno" intervjuiranje
- korak 4: Intervjuiranje kroz testiranje i analizu slučajeva

Korak 1: Analiza zadatka i selekcija eksperta

Tijekom izvršavanja ovog koraka, potrebno se sastati sa rukovodstvom poduzeća (dobiti odobrenje za rad), ekspertima i korisnicima, da bi se utvrdio zadatak (okružje zadatka - task analysis) i identificirao jedan ili više eksperata s kojim će se razvijati sustav. Tada se ne sprovodi akvizicija, već se nastoji dobiti dobar pregled zadatka, inputa i outputa, i osnovnih metodologija rješavanja problema.

U stvari, to je faza u kojoj inženjer znanja uči o problemu; analiziranjem slučajeva iz prošlosti i iz različitih izvora (literature, konzultiranjem i sl.).

Naravno da je neophodno utvrditi eksperte koji su voljni raditi na razvoju ekspertnog sustava. Ovo je ključni korak, jer ukoliko se ne pronađe ekspert sa zadovoljavajućim osobinama, slijedeći koraci se ne izvršavaju, ili

se zadatak reformulira i ponovno, u novom svjetlu razmatra; ili se odustaje od projekta.

Korak 2: Pripreme za intervjuiranje eksperta

Kao što je već razmatrano (metode i tehnike akvizicije) intervjui se mogu zasnivati na različitim načinima pitanja. Bitno je napomenuti, da eksperti uvijek preferiraju razgovarati sa osobom iz njihovog područja rada. Ukoliko je inženjer znanja toliko neobaviješten, i ekspert osjeća da ga treba mnogo čemu podučavati, moguće je da odluči napustiti projekt, jer bi za njega trebalo mnogo vremena.

Ako se ispituje eksperta o procedurama koje koristi kada analizira i rješava problem, ugodnije će to obavljati upotrebljavajući tehnički riječnik svoje domene. Sve ovo sugerira, da inženjer znanja mora utrošiti što je moguće više vremena učeći o domeni, prije no što ikako počne raditi sa ekspertom. To je najlakše činiti, formirajući analogiju sa bliskim, već poznatim sustavom. Individue koje uživaju razvijati nove ekspertne sustave u različitim domenima, su one, koje su uspješne u učenju novih područja za kratko vrijeme.

Osim učenja, potrebno je sačiniti strategiju ispitivanja eksperta, odgovarajući na pitanja tipa:

- kako učestali i koliko dugi će biti intervjui? (što će ovisiti o rasporedu eksperta. Utvrđeno je da su najproduktivniji sastanci jedanput tjedno, sa dužinom trajanja od 3-5 sati. Nakon svakog sastanka, inženjer znanja revidira i predstavlja znanje koje je pribavio, ili na papir ili eksperimentiranjem sa bazom znanja),

- koliko inženjera znanja (onih koji razvijaju sustav) će sudjelovati u ispitivanju? Odgovor na ovo pitanje ovisit će o preferiranju inženjera znanja: neki vole raditi sami, neki ne; i o veličini projekta.

- kako će naučene informacije, kroz intervjuiranje, biti dokumentirane?

Odgovor i na ovo pitanje, ovisi o preferiranju inženjera znanja. Većina ih vode bilješke ili snimaju razgovor, pa ga uvijek i nanovo preslišavaju. Dok inženjer analizira i studira rezultate ispitivanja, eksperti prikupljaju primjere (slučajeve) iz prošlosti koji će poslužiti za testiranje.

Uloga i značaj testiranja primjera je ogromna, i oni se primjenjuju i u cilju kreiranja prototipa baze znanja i u cilju razvoja cijelog sustava. Da bi se provjerila korektnost rada, uvijek i nanovo je potrebno prikupljati slučajeve iz stvarnog života i rada eksperta.

Korak 3: "Početno" intervjuiranje

Kada je utvrđena strategija ispitivanja eksperta moguće je ostvariti njezino stvarno sprovođenje. Kao opće pravilo, dva ili tri prva intervjuja proteći će u nastojanju da se dobije jasna slika ekspertovog procesa odlučivanja. Cilj je dobiti toliko informacija da se može početi crtati proceduralni model, mreža ili stablo konteksta (odnosno mapa znanja) koja će opisati osnovne objekte tj varijable. Moguće je aranžirati sastanke

eksperta i korisnika i onda kroz njihovu interakciju i konzultiranje dobiti informacije o ekspertu, ili promatrati više eksperata. Takve konzultacije ekspert-korisnik i npr. ekspert-ekspert imaju osobine primjera (slučaja-case) kojima se testira sustav.

Objekt razgovora se kreće od općih, generalnijih tema; ka specifičnim, da bi okončali specifičnim detaljima. Korak 3 se može završiti onog trenutka kada inženjer znanja smatra da ima razvijen prototip sustava koji može riješiti jedan do tri specifična slučaja. Ne može se očekivati da će prvi razvijeni prototip biti i osnova za razvoj stvarnog sustava. Nakon nekoliko testiranja on se obično rearanžira (i mapa znanja i baza znanja). Ovaj proces se ponavlja nekoliko puta dok se ne kreira baza znanja koju je moguće dalje sistematično razvijati dodavanjem novih pravila i testiranjem na novim slučajevima.

Korak 4: Intervjuiranje kroz testiranje i analizu slučajeva

Iskusniji inženjeri znanja razvijaju minimalnu mapu znanja i nastoje brzo izgraditi bazu znanja, dok drugi preferiraju dugotrajno aranžiranje mape prije što nastave proces njezinog dekodiranja u bazu. Idealna mapa znanja trebala bi sačinjavati samo objekte, veze (relacije) i attribute neophodne za bazu znanja, bez pretjeranih specifičnih informacija. Veličina i priroda znanja uveliko će odrediti trajanje prethodne faze. Veliko i kompleksno znanje eksperta zahtijevat će duže trajanje inicijalne analize, dok manja i bolje organizirana ekspertiza omogućava brži prelazak na testiranje primjera. Kada se osjeti da ekspert, osnovnim informacijama dodaje one tipa "dobro ih je znati", a ne "potrebno je znati", to je indikator nastavka rada izvršavanjem koraka 4.

Probanje primjera, istraživanje preporuka i određivanje dijagrama rezoniranja sustava jeste najbolji način fokusiranja ekspertove pažnje. Kada ekspert vidi prvi prototip, neophodno je donijeti odluku da li prepravljati mapu znanja, ili ići dalje i kroz probanje primjera ići dalje i dodavati nova specifična znanja. Pri donišanju takve odluke može se konzultirati i sa korisnicima.

Ako sustav od njih traži informacije koje korisnici ne posjeduju to je znak da treba razvijati pravila koja će pomoći da sustav dobiva više specifičnih informacija, i da je razvijena struktura znanja još uvijek na apstraktnijem (ekspertovom) stupnju, no što korisnik treba. Sa druge strane, sustav može pružati preporuke koje korisnik ne zna interpretirati, što signalizira da treba uložiti više napora pri definiranju specifičnih ciljeva i zaključaka koje sustav čini.

Dobar ekspertni sustav je uvijek kombinacija ekspertnog znanja i ulaza/izlaza koje formira krajnji korisnik. Dobar ekspert obično zna oboje, premda nekada ne zna objasniti inženjeru koju vrstu tehnika ili pitanja koristi da bi dobio te podatke.

Akvizicija znanja je danas ipak više umjetnost nego tehnologija. Ona zahtijeva sposobnost rada sa ekspertima, da bi im se pomoglo da identificiraju svoje znanje i sposobnost (vještinu) izgrađivanja efikasnog i

efektivnog modela tog znanja u bazu znanja. U bliskoj budućnosti, razvijati će se različite nove tehnike i alati, koji će pomoći inženjeru znanja u tom poslu, ali u ovom trenutku još uvijek se uči i saznanje o tom procesu. Pokušali smo ponuditi neke heuristike, no ipak se sve svodi na posjedovanje vještina dobrog komuniciranja i ogromne količine zdravog razuma i intuicije.

4. UMJESTO ZAKLJUČKA: POŽELJNE OSOBINE EKSPERTA U PROCESU AKVIZICIJE ZNANJA

Na osnovi prikazanog procesa akvizicije znanja, pokušati ćemo utvrditi koje su poželjne osobine eksperta da bi njegovo znanje moglo biti iskorišteno za kreiranje ekspertnog sustava.

Osnovni uvjet koje znanje eksperta mora udovoljiti jest da se radi o praktičnom (tj. specifičnom, surface znanju), a ne teorijskom; jer se samo ono može obuhvatiti prikazanim metodama.

Sljedeća osobina jest da ekspert mora biti visoko motiviran za rad sa inženjerom znanja: ili će biti svjestan da će mu izgrađeni sustav olakšati posao ili će biti novčano stimuliran od rukovodstva poduzeća. Ovu osobinu nazvat ćemo sa "motiviranost za kooperaciju", a ona se izravno odražava na ekspertovo ponašanje u okviru raspoloživog vremena i sredstava; na njegovu uposlenost (vrijeme sastanaka), pa i na savladavanje konfliktnih situacija (koje su moguće u susretu sa drugim ekspertima, korisnicima pa i inženjerom znanja). Poželjnom osobinom se smatra "biti vrlo motiviran".

Na cjelokupan proces akvizicije znanja u velikoj mjeri utječe komunikacijska sposobnost eksperta (a i inženjera znanja). U okviru ove osobine važan je ekspertov osjećaj za bitne, temeljne informacije o problemu, podešavanje razgovora temi i održavanje teme razgovora; održavanje prave razine detaljnosti informacija i sl.

Ova osobina ima presudnu, eliminacijsku ulogu; i ukoliko se, putem metode akvizicije, ne pronađe pravi put za njezino savladavanje, jedini način crpljenja znanja jeste pronaći novog eksperta.

Pojedini eksperti, zbog malog ili velikog poznavanja mogućnosti ekspertnih sustava imaju prevelika ili mala očekivanja od izgrađenog ekspertnog sustava. Oni koji poznaju moć/nemoć ekspertnih sustava očekivat će od njegovog razvoja pomoć i olakšanje svog posla, bez opasnosti i straha da će ga sustav zamijeniti u potpunosti. Kod osobine nazvane "očekivanja od razvijenog ekspertnog sustava" koja se kreće u skali od nipodaštavanja i neprihvatanja novog do prevelikih očekivanja, poželjnim se smatra - "biti informiran" o ulozi i mogućnostima ekspertnog sustava.

Poznata je pojava da ljudi prilikom ispitivanja o sebi, nastoje pružiti što ljepšu i povoljniju sliku, tj skloni su uljepšavanju sebe i svog posla. To može izazvati dosta problema inženjeru znanja i umnogome ovisi i od

njegovih osobina hoće li steći ekspertovo povjerenje i smanjiti taj "obrambeni refleks".

Ovim imenom ćemo nazvati sklonost eksperta ka samouljepšavanju, i mjerit ćemo je skalom od "mali", kao poželjnom varijantom; do "veliki" kao uvjetom eliminacije.

Ekspertni sustavi na pojedinim razinama odlučivanja imaju različite uloge. Na nižim stupnjevima (operativnom i taktičkom) može se zahtijevati od njihovog razvoja zamjenjivanje donositelja odluka, no na strateškoj razini, ekspertni sustavi mogu imati samo ulogu olakšavanja i potpomaganja donošanja odluka.

Pri razvoju ekspertnih sustava za niže razine odlučivanja, pri akviziciji znanja potrebno je posjedovati "znanje o korisniku" tog sustava, jer on tada zamjenjuje eksperta-konzultanta. Tada je potrebno da ekspert svoje znanje prilagođava potrebama i znanju korisnika tog sustava. Kod razvoja ekspertnih sustava za potrebe strateškog odlučivanja, takvo znanje nije potrebno, ili je potrebno u manjoj mjeri, jer je i korisnik u stvari ekspert. Znanje o potrebama korisnika izraženo kroz najmanju mjeru "poznavanje" smatra se dovoljnim (kao suprotni pol osobine smatra se "znanje" o korisniku).

Osobine eksperta pri procesu akvizicije nije moguće striktno odvojiti jedne od drugih, međusobno su povezane i uvjetovane. Kao ključne osobine pojavljuju se posjedovanje komunikacijske sposobnosti i motiviranosti za suradnju, a sve ostale navedene se mogu deducirati, stvoriti ili izvoditi na osnovu njih.

LITERATURA

1. B. G. Buchanan, E. H. Shortliffe: " Rule - Based Expert Systems - The MYCIN Experiments of the Stanford Heuristic Programming Project ", Addison- Wesley Publishing Comp., 1984.
2. A. Barr, P. R. Cohen, E. A. Feigenbaum: " The Handbook of Artificial Intelligence", Vol. IV, Addison- Wesley Publishing Comp, 1989.
3. P. Harmon, B. Sawyer : " Creating Expert Systems For Business and Industry ", John Wiley and Sons, 1990.
4. A. Fulgosi: " Psihologija ličnosti - teorije i istraživanja ", Školska knjiga, Zagreb, 1981.
5. R. A. Edmunds: " The Prentice - Hall Guide to Expert Systems ", Prentice - Hall, 1988.
6. N. Ashrafi, J. P. Kuilboer, J. M. Wagner: " Expert systems reliability: A life cycle approach ", Information & Management 28, 1995, 405- 414.

Vanja Bevanda, M.Sc.

Assistant

Faculty of Economics, Mostar

THE PROCESS OF KNOWLEDGE ACQUISITION

Summary

The paper shows first level activities in the formation of an expert system, organized through the meta model process of acquiring knowledge. Concrete instructions are given for working with an expert. Within the framework of engineering knowledge, the desired characteristics of an expert are determined based on this process of acquiring expert knowledge, which enables knowledge engineers to effectively create data bases.

Key words: *knowledge acquisition, knowledge engineering, expert system, expert.*