

Ekspertski sistemi

Lekcija 11: INDUKCIONI SISTEMI

Indukcioni sistemi

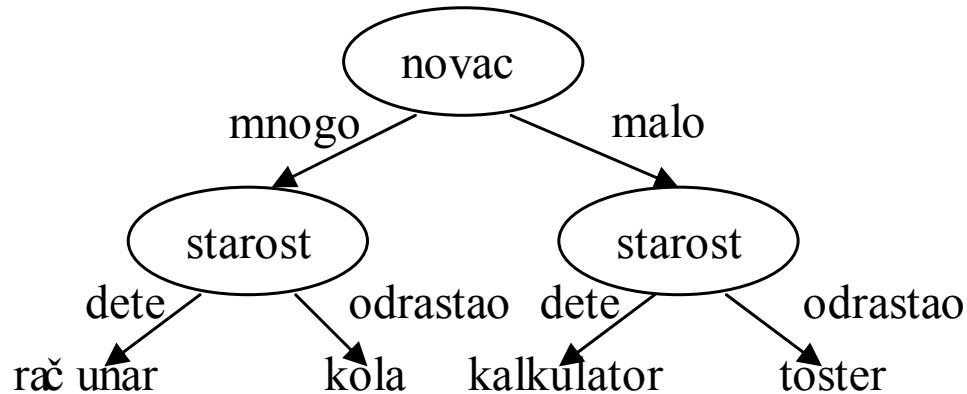
- Zbog problema koji se pojavljuju pri dobijanju znanja od eksperta, tehnike koje automatizuju proces sakupljanja znanja putem mašinskog učenja su postale vrlo privlačne.
- Mašinsko učenje je već dugo prepoznato kao bitna karakteristika veštačke inteligencije.
- Metode učenja se mogu klasifikovati na sledeće klase:
 - učenje napamet
 - učenje saopštavanjem
 - učenje putem primera
 - učenje preko analogija
- Najrasprostranjenija od tehnika učenja u eksperckim sistemima je učenje putem primera – indukcija.

Indukcioni sistemi

- Indukcija je proces izvođenja opštih pravila iz znanja koja se sadrže u konačnom skupu primera. Na primer, ako osoba A kaže osobi B da voli slikarstvo, vajarstvo, poeziju, onda osoba može da zaključi da osoba A voli umetnost.
- Induktivno učenje se može posmatrati kao pretraživanje prostora problema radi nalaženja rešenja.
- Primer - problem nalaženja poklona. Neka su glavni koncepti problema: novac, starost osobe, pokloni.
- Usvajaju se sledeće pretpostavke
 - Novac – mnogo ili malo
 - Starost – dete ili odrasla osoba

Indukcioni sistemi

Faktori odlučivanja		Rezultati
Novac	Starost	Poklon
mnogo	odrastao	Kola
mnogo	dete	Računar
malo	odrastao	Toster
malo	dete	Kalkulator



Indukcioni sistemi

- IF mnogo novca

AND kupuje se poklon za odraslu osobu

THEN kupiti kola

- IF mnogo novca

AND kupuje se poklon za dete

THEN kupiti računar

- IF malo novca

AND kupuje se poklon za odraslu osobu

THEN kupiti toster

- IF malo novca

AND kupuje se poklon za dete

THEN kupiti kalkulator

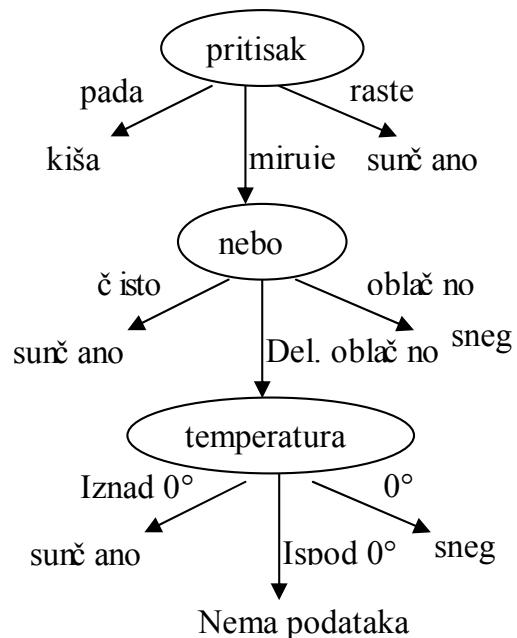
ID3

- ID3 je induktivni algoritam koji se koristi u većini ekspertskega sistema.
- ID3 uzima skup primera problema i generiše stablo odlučivanja.
- Primer je kombinacija faktora odlučivanja, vrednosti faktora odlučivanja, i akcije specifične za taj primer.

ID3

Faktori odlučivanja				Rezultat
Temperatura	Vetar	Nebo	Pritisak	Prognoza
Iznad 0°	Zapadni	Oblačno	Pada	Kiša
Ispod 0°	*	Oblačno	Miruje	Sneg
Iznad 0°	Istočni	Oblačno	Raste	Sunčano
Iznad 0°	*	Delimčno oblačno	Miruje	Sunčano
*	*	Čisto nebo	Miruje	Sunčano
Iznad 0°	Južni	Čisto nebo	Pada	Kiša
0°	Severni	Delimčno oblačno	Miruje	Sneg

* - označava da taj faktor u tom primeru nije bitan.



ID3

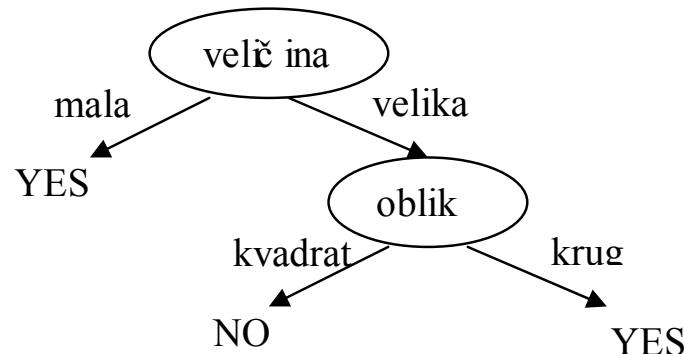
- Izbor najpre najvažnijeg elementa – prva odluka je izbor atributa barometarski pritisak kao korena stabla. Ispitivanje prvo ovog faktora je najefikasnije, pošto dva od tri moguća odgovora vode neposrednom predviđanju, bez potrebe da se ispituju faktori nebo ili temperatura. Dakle, ID3 smešta najvažnije faktore odlučivanja blizu korena stabla.
- Nema podataka – povremeno se dešavaju slučajevi da se ne može dobiti rezultat. To označava situaciju za koju ne postoje primeri na osnovu kojih se može izvući zaključak. Ako se nađe na ovakve situacije, to je obično znak da je skup primera nedovoljan i da ga je potrebno upotpuniti novim primerima koji bi podržali te mogućnosti.
- Isključivanje nevažnih faktora – još jedna važna odlika ID3 je da ustanovi da originalni skup sadrži atribut smer vetra, ali ovaj faktor se ne pojavljuje nigde u stablu odlučivanja. ID3 je odlučio, na osnovu skupa primera, da je ovaj faktor nebitan za predviđanje vremena. Čovek koji je ekspert za predviđanje vremena može da bude nesvestan da je ovaj faktor nevažan.

Algoritam rada ID3

- ID3 je naslednik sistema za učenje koncepata (CLS – Concept Learning System).
- CLS rešava zadatke učenja sa jednim konceptom i koristi naučene koncepte da klasificuje nove primere.
- CLS može da otkrije klasifikaciono pravilo ili stablo odlučivanja za skup primera koji pripadaju dvema klasama i da koristi ovo pravilo da klasificuje novi primer u jednu od ove dve klase.
- Primer se klasificuje polazeći od čvora stabla, obavljajući testiranje, i prateći grane dok se ne dostigne čvor, koji se označava sa YES ili NO, da li je primer u klasi.

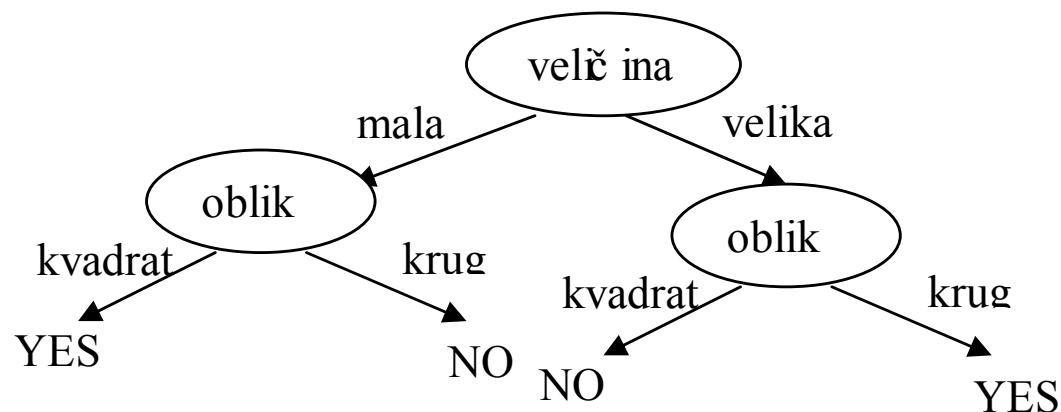
Algoritam rada ID3

- Neka su dati primeri sa karakteristikom oblik (kvadrat, krug) i veličina (mali, veliki) – primer košarkaška lopta
- YES i NO čvorovi predstavljaju rezultate praćenja date putanje kroz stablo. Ako se stigne do čvora YES, tada odluke donete na svakom od prethodnih čvorova su konzistentne sa konceptom velikog kruga, t.j. košarkaške lopte. Ako se dođe do čvor NO tada odluke ne podržavaju koncept, t.j. nije košarkaška lopta.



Algoritam rada ID3

- **Primer (veliki, kvadrat) - čvor veličina, čvor oblik, čvor NO, koji označava da ovaj novi primer nije slučaj koncepta veliki krug.**
- **Primer (mali, kvadrat) - čvor veličina, NO. Nije uopšte potrebno da se razmatra čvor oblik.**
- **Visoko diskriminujući čvor treba smestiti u koren ili blizu korena stabla odlučivanja kako bi se poboljšala efikasnost procesa odlučivanja.**



CLS

- **CLS algoritam počinje praznim stablom odlučivanja i iterativno gradi stablo dodavanjem čvorova odlučivanja dok stablo ne klasificuje ispravno sve primere obučavanja u skupu C.**
- **Ovaj algoritam se odvija na sledeći način:**
 - Ako su svi primeri u C pozitivni, formirati čvor YES i stati. Ako su svi primeri u C negativni, formirati čvor NE i stati. Inače, odabratи, prema nekom heurističkom kriterijumu, atribut A sa vrednostima V_1, V_2, \dots, V_n , i formirati čvor odlučivanja
 - Podeliti priemre za obučavanje u skupu C u podskupove prema vrednostima C_1, C_2, \dots, C_n , za V
 - Primeniti algoritam rekurzivno na svaki podskup C_i

ID3 algoritam

- CLS algoritam zahteva da svi primeri za obučavanje budu raspoloživi u prvom koraku, što ograničava broj primera koji se mogu efektivno rešiti. ID3 algoritam radi sa podskupovima primera radi rešavanja složenih problema koji uključuju veliki broj primera.
- Heuristika korišćena u prvom koraku služi za izbor najpre najdiskriminatornijeg atributa. ID3 koristi informacioni pristup za procenu diskriminatorske snage svakog atributa.
- Za neki dati primer, stablo odlučivanja generiše poruku vezanu za klasu primera, t.j. ako je primer vezan za klasu YES, daje se poruka »plus«. Ako su verovatnoće »plus« i »minus« poruka p^+ i p^- respektivno, tada je informacioni sadržaj
 - $p^+ \log_2 p^+ - p^- \log_2 p^-$ (1)

ID3 algoritam

- p^+ je dato proporcijom primera u C klase »plus« a p^- dato proporcijom primera u klase »minus«.
- $M(C)$ se sada može definisati da predstavlja očekivani informacioni sadržaj poruke iz stabla odlučivanja za skup C primera, i dat je jednačinom (1).
- Izbor najdiskriminatornijeg atribut - atribut kojim treba testirati susedne grane podskupove C_i od C.
- Za bilo koji atribut sa vrednostima V_1, V_2, \dots, V_n , novočekivana informacija koja treba da se dobije biranjem ovog atributa je data sa

$$B(C, A) = \sum (\text{verovatnoća da je vrednost od } A \text{ jednaka } V_i) \quad (2)$$

- Jednačina (2) se može primeniti na svaki atribut i odabira se onaj koji maksimizira očekivani informativni dobitak prema

$$M(C) - B(C, A) \quad (3)$$

- Novoočekivana količina informacija treba da bude mala kada se bira ovaj atribut A da bi preostali deo imao što manje da radi.

ID3 algoritam

1. 1. Odabratи slučajni podskup veličine W iz celokupnog skupa primera za obučavanje (W se naziva prozor)
2. 2. Primjeniti CLS algoritam za formiranje stabla odlučivanja ili pravila za odabrani prozor W .
3. 3. Pretražiti celokupan skup primera (ne samo prozor) da bi se pronašli izuzeci od tekućeg pravila.
4. 4. Ako postoje izuzeci, uključiti ih u prozor i ponoviti korak 2, inače stati i prikazati poslednje pravilo.

ID3 algoritam

- Algoritam konvergira iterativno konačnom pravilu koje obuhvata koncept. Svrha koraka 1 je da se formira mali skup iz svih primera, prozor, jer pun skup primera može da bude suviše veliki. Ovim se korakom povećava efikasnost algoritma.
- CLS algoritam služi kao potprogram ID3 algoritmu. CLS algoritam prvo nalazi atribut (čvor odlučivanja) koji najbolje diskriminiše između pozitivnih i negativnih primera, i deli podatke u odnosu na taj atribut. ID3 algoritam koristi heuristiku zasnovanu na informacionom sadržaju poruke dobijene od stabla odlučivanja za dati primer.
- Po izboru najdiskriminatornijeg atributa, podaci se dele u dva podskupa. Svaki podskup se zatim deli na sličan način sve dok se ne dobiju podskupovi koji sadrže podatke samo jedne klase. Konačan rezultat je stablo odlučivanja koje se može iskoristiti da se klasifikuju novi primjeri.

ID3 - primer

Faktori odlučivanja				Rezultat
	Nebo	Pritisak	Vetar	Kiša
1	Č	R	S	-
2	O	R	J	+
3	O	S	S	+
4	Č	O	S	-
5	O	O	S	+
6	O	R	S	+
7	O	O	J	-
8	Č	R	J	-

Nebo		Oblačno
Čisto	Oblačno	
1. čisto, raste, severni	-	2. oblačno, raste, južni
4. čisto, pada, severni	-	3. oblačno, stabilno, severni
8. čisto, raste, južni	-	5. oblačno, pada, severni
		6. oblačno, raste, severni
		7. oblačno, pada, južni

ID3 - primer

Podskup za granu čisto sadrži samo primer jedne klase i ne zahteva dalju razradu. Razvijajući i dalje atribut pritisak daje sledeće rezultate

	oblačno			
	pritisak			
pada	stabilno	raste		
5. oblačno, pada, severni	+ 3. oblačno, stabilno, severni	+ 2. oblačno, raste, južni		+
7. oblačno, pada, južni	-	6. oblačno, raste, severni		+

Dalje, potrebno je izvršiti dalju ekspanziju za podskup pritisak pada.

	pada			
	vetar			
severni		južni		
5. oblačno, pada, severni	+	7. oblačno, pada, južni		-

ID3 - primer

Ostaje da se proveri da li je najbolji diskriminatorskič vor nebo.

Skup primera C sadrži 4 u klasi + i 4 u klasi -. Prema jednoj od prethodnih jednačina $M(C) = -(4/8)\log_2(4/8) - (4/8)\log_2(4/8) = 1$ bit

Ako se prvo testira atribut vetar dobija se jednonivoosko stablo:

		vetar		
severni		južni		
1	-		2	+
3	+		7	-
5	+		8	-
6	+			

ID3 - primer

- Informacija potrebna za granu severni može se pronaći iz
 $M(\text{severni}) = -(3/5)\log_2(3/5) - (2/5)\log_2(2/5) = 0,971 \text{ bita}$
- a za granu južni
 $M(\text{južni}) = -(1/3)\log_2(1/3) - (2/3)\log_2(2/3) = 0,918 \text{ bita}$
- Očekivani informacioni sadržaj je
 $B(C,\text{veter}) = (5/8) + 0,971 + (3/8) * 0,918 = 0,951 \text{ bita}$
- Informacija koja se dobija korišćenjem ovog algoritma
 $M(C) - B(C,\text{veter}) = 1 - 0,951 = 0,049 \text{ bita}$
- Ako se isti postupak primeni na atribut nebo dobija se
 $M(\text{čisto}) = -(3/3)\log_2(3/3) = 0 \text{ bita}$
- $M(\text{oblačno}) = -(4/5)\log_2(4/5) - (1/5)\log_2(1/5) = 0,722 \text{ bita}$
- $B(C,\text{nebo}) = (3/8) + 0 + (5/8) * 0,722 = 0,412 \text{ bita}$
- Informacija koja se dobija koristeći atribut nebo je
 $M(C) - B(C,\text{nebo}) = 1 - 0,452 = 0,548 \text{ bita}$
- Ako se isti postupak primeni na atribut pritisak, dobija se 0,156 bita.
- Znači da je najpogodniji diskriminatorski čvor nebo.

Prednosti ID3

- **Biranje skupa problema** – I CLS i ID3 algoritmi rade dobro kada se radi o problemima sa samo jednim konceptom. Izbor podskupa problema za obučavanje, prozora, jedna od osnovnih snaga. Ovaj metod izbora prozora se često naziva filtriranje upravljano izuzecima. Ova tehnika omogućava programu da se fokusira na one primere za obučavanje koje su protivne očekivanjima, koji su primeri potrebni da se poboljša predstava koncepta koji se uči.
- **Izbor najboljeg diskriminatorskog čvora** – ID3 primenjuje informacioni pristup u izboru najboljeg diskriminatorskog čvora. Ovaj pristup obezbeđuje efikasnost sistema.

Nedostaci ID3

- pravila nisu probabilistička
- nekoliko identičnih primera nema više efekta od jednog
- ne radi sa protivrečnim primerima
- rezultati su stoga jako osetljivi na manje izmene u primerima za obučavanje.
- Praktičan problem sa stablima odlučivanja je da je teško razumeti koncept koji se uči za velika stabla odlučivanja. Uprkos tome, ID3 se pokazao efektivnim u izgradnji dobrih ekspertskeih sistema.

Razvoj induktivnog eksperckog sistema

- **Odrediti cilj:** Pretraživanje stabla odlučivanja će dovesti do jedne od konačnog skupa odluka na osnovu putanje kroz stablo. Svaka odluka se odnosi za neki unapred određeni cilj. U problemu izbora poklona cilj je bio da se izabere pravi poklon za određenu osobu.
- **Odrediti faktore odlučivanja:** faktori odlučivanja su čvorovi atributa u stablu odlučivanja. Ovi faktori uključuju odlike problema koji bi se razmatrali kod donošenja konačne odluke. Na primer, u problemu izbora poklona, uzeti su u obzir kao što su novac i starost i pol osobe za koju se kupuje poklon. Ovo je često najteži zadatak u razvoju induktivnog sistema. Ako su faktori odlučivanja slabo izabrani ili nepotpuni, krajnji rezultat bi bio netačan.
- **Odrediti vrednosti faktora odlučivanja:** Potrebno je zadati listu mogućih vrednosti za attribute stabla odlučivanja. Na primer, faktor odlučivanja novac ima vrednost (malo, mnogo). Dobar izbor vrednosti je važan. Ako se posmatra navedeni slučaj, korisnik može da utvrdi da je ovo suviše subjektivno, ili pak želi da potroši prosečno novca – vrednost koja nedostaje u listi. Stoga se korisnik mora uključiti rano u projekat da bi pomogao u definisanju efektivnog skupa vrednosti.

Razvoj induktivnog eksperetskog sistema

- **Odrediti rešenje:** Mora se odrediti lista konačnih odluka koju sistem mora da učini - listovi stabla odlučivanja. Na primer, mogući pokloni.
- **Formiranje skupa primera:** Primeri sadrže poznavanje problema i koriste se za donošenje inteligentnih odluka. Ovi primeri povezuju vrednosti faktora odlučivanja sa konačnim ishodima, i mogu da se dobiju od eksperta domena ili iz zapisa prošlih događaja. Ako primeri dolaze iz nekoliko izvora, potrebno je čuvati zapis o njihovom izvoru. U slučaju da performanse sistema ne zadovolje očekivanja, tada brisanje primera iz manje pouzdanog izvora bi moglo da poboljša situaciju.
- **Formiranje stabla odlučivanja:** Potrebno je da se koriste induktivni algoritmi kao što je ID3 da bi se formiralo stablo odlučivanja. U slučaju da se neki faktor odlučivanja ne pojavi u stablu, ne uklanjati ga iz skupa podataka. Kasnije kada se dodaju drugi primeri, faktor se može pojaviti kada se indukuje novo stablo.

Razvoj induktivnog eksperckog sistema

- **Testirati stablo:** Pri testiranju se upoređuju predviđeni rezultati sistema sa stvarnim studijama slučaja. Mogu se izabrati slučajevi iz skupa originalnih primera koji nisu bili korišćeni pri formiranju stabla odlučivanja ili koristiti skup budućih primera.
- **Izvršiti reviziju sistema:** Revizija sistema se obično sastoji od dodavanja novih faktora odlučivanja ili dodavanja ili brisanja primera. Tipični problemi koji se dešavaju u toku testiranja spadaju u neku od sledećih kategorija: netačan rezultat, nema rezultata, protivrečan rezultat.
 - Netačan rezultat je onaj koji se razlikuje od očekivanog. Ovaj problem se dešava jer je poznavanje sistema slabo, sistem nema dovoljno faktora odlučivanja, ili sistemu nedostaju vrednosti faktora odlučivanja. Sistem je slab ako je izvor znanja nepouzdani ili skup primera ne pokriva širok opseg problema. Problemi se mogu pojaviti ako sistemu nedostaju važni faktori odlučivanja ili vrednosti.
 - Kada nema rezultat, znači da skup primera ne uključuje vrednosti faktora odlučivanja za date test slučajeve - uključiti nove primere.
 - Protivrečan rezultat dolazi kada se dobije više od jednog rezultata za isti skup vrednosti faktora odlučivanja. Radi korekcije, treba dodati nove faktore ili vrednosti koje će dovesti do odgovarajuće diskriminacije.

Primer razvoja sistema

Cilj: napraviti ekspertske sisteme koji će predviđati pobedu ili poraz našeg tima u sledećem susretu.

Faktori odlučivanja: lokacija meča, vreme, istorija našeg tima i istorija protivnika.

Vrednosti faktora odlučivanja:

Lokacija	Vreme	Istorijski rezultat	Istorijski rezultat
Kod kuće	Kiša	Slabo	Slabo
Na strani	Hladno	Prosечно	Prosечно
	Umereno	Dobro	Dobro
	Vruće		

Rešenje: binarno – naš tim ili dobija ili gubi.

Primer razvoja sistema

- Primeri: Potrebno je sakupiti skup primera koji bi se iskoristili za generisanje stabla odlučivanja. Neka je polovina sezone prošla, te se iz prethodnih osam igara mogu dobiti primeri sa vrednostima faktora odlučivanja.
- Stablo odlučivanja: Čvorovi stabla odlučivanja su vreme, lokacija i istorija našeg tima. ID3 algoritam je odlučio da je faktor istorija privremeno nevažan za predviđanje ishoda igre. Međutim, kasnije će se ispostaviti da je on ipak važan.
- Testiranje: Stablo odlučivanja se može iskoristiti da se predvidi da li će naš tim dobiti ili izgubiti buduće mečeve. Polazeći od njega dobija se tabela. Tabela predviđanja pokazuje da neka predviđanja nisu dobra. Samo tri prognoze su dobre. Očigledno je da treba utvrditi razloge za loše prognoze. Došlo se do zaključka da je potrebno uzeti u obzir još jedan faktor – zdravlje tima, sa vrednostima slabo, prosečno i dobro.
- Kao sledeći korak, potrebno je vratiti se natrag nad prošlim igrami i dobiti vrednost zdravlja tima i dodati ovaj faktor i novi primer u naš sistem. U stablu se sada pojavljuje zapis o protivniku. Upoređivanjem rezultata predviđanja dobijenih uvođenjem novog faktora sa stvarnim rezultatima, vidi se da su predviđanja odlična.

Prednosti indukcije

- **Otkrivanje pravila iz primera:** Na osnovu urađenih primera o nekom problemu iz kojih se može izvesti skup pravila odlučivanja.
- **Izbegavanje problema izbegavanje znanja:** Indukcija nudi tehniku kod koje se znanje sistema stiče direktno preko prošlih primera. Ova tehnika može da izbegne probleme vezane za pokušaje sticanja znanja direktno od eksperta.
- **Proizvodnja novog znanja:** Induktivno sredstvo može da proizvede ekspertske sisteme koji bi upravljao donošenjem budućih odluka, čak iako ekspert nije eksplicitno svestan znanja za odlučivanje. Ovo je moguće jer indukcija može da otkrije oblike odlučivanja koji nisu očigledni, čak ni ekspertu domena.
- **Otkrivanje kritičnih faktora odlučivanja:** Indukcija otkriva najvažnije faktore odlučivanja. Ovo preim秉stvo može da vodi ka sistemu koji odlučuje na osnovu samo nekoliko faktora, koji značajno poboljšavaju inteligenciju i efikasnost sistema.
- **Eliminisanje nevažnih faktora odlučivanja:** Često, se za faktore koji u početku izgledaju važni u donošenju konačnih odluka, utvrdi kroz indukciju da su nebitni. Ovo je značajno za samog eksperta i efikasnost sistema, ali se mora ipak biti obazriv, jer se dodavanjem novih primera može desiti da uklonjeni faktori ponovo postanu važni.

Prednosti indukcije

- **Otkrivanje protivrečnosti:** Zbog načina na koji se primjeri unose u indukciione sisteme, neka razvojna okruženja mogu lako da otkriju primere koji daju protvrečne rezultate za isti skup vrednosti faktora odlučivanja.

Faktori odlučivanja	Rezultati
Pritisak pumpe	Temperatura pumpe
Nizak	Visok
Nizak	Visok

- Induktivno razvojno okruženje može da otkrije protivrečne rezultate i o tome obavesti projektanta. U nekim slučajevima, protivrečnost može da bude prihvatljiva. Za date vrednosti faktora odlučivanja, oba rezultata mogu da budu logična.
- U većini slučajeva, otkrivena protivrečnost označava problem. Priblem može da bude u lošem primeru, ili još češće, ili u faktorima odlučivanja ili vrednostima koje su neadekvatne.

Prednosti indukcije

Ako se posmatra ponovo primer pumpe i otkrivanje protivrečnosti. Ekspert može da utvrdi da bi trealo uzeti u obzir broj obrta/min motora koji kontrolišu pumpu. Ekspert može da daje i vrednosti za ovaj faktor koje vode ka neprotivrečnim rezultatima.

Faktori odlučivanja			Rezultati
Broj obrtaja/min	Pritisak pumpe	Temperatura pumpe	Uslovi
Visok	Nizak	Visok	Oticanje pumpe
Nizak	Nizak	Visok	Normalna pumpa

Dodavanje ovog novog faktora odlučivanja ilustruje ne samo kako se može eliminisati protivrečnost, već otkriveni problemi mogu da odvedu ka otkrivanju dodatnog znanja domena.

Nedostaci

- **Teškoće izbora dobrih faktora odlučivanja:** Efikasnost sistema zavisi od izbora dobrih faktora odlučivanja. Na primer, koje faktore treba uzeti u obzir pri razvoju sistema za predviđanje pobjednika fudbalske igre.
- **Teškoće u razumevanju pravila:** Većina induktivnih sredstava proizvode rezultate u formi stabla odlučivanja. Kod složenih problema, teško je razumeti proces odlučivanja praćenjem kroz stablo. Ovo stablo postaje naročito složeno kada se sredstvo koristi za određivanje pravila radi njihovog uključivanja u standardne produkcijske sisteme.
- **Primenjivi su samo kod klasifikacionih problema:** Indukcija je dobra za probleme u kojima se skup vrednosti atributa može klasifikovati u neke očekivane rezultate. Na primer, problem dijagnoze pokušava da klasificuje skup simptoma u zadato stanje greške. Drugi tipovi problema, kao što su planiranje ili projektovanje, teško se mogu rešiti induktivnim pristupom.