

PRIMJENA DATA MININGA ZA KREIRANJE INFORMACIONIH SISTEMA U OBLASTI LJUDSKIH RESURSA

Vlado Simeunović, Univerzitet Sinergija, Bijeljina, Republika Srpska,
vlado.simeunovic@gmail.com

Biljana Trupnić, Bijeljina, Republika Srpska,
trupnic555@hotmail.com

Apstrakt: Rad se bavi pitanjima doprinosa koje Data mining (pretraživanje podataka) može da pruži u okviru funkcionisanja ljudskih resursa u organizacijama. Na početku rada smo pružili osnovni uvod u tehnike i procese pretraživanja podataka (DM) i pregled literature sa koracima kako pretraživati ove informacije. Takođe smo diskutovali o značaju čuvanja (skladištenja) podataka i razmatranje datamart podataka. Izvršeno je upoređivanje razlike između pretraživanja podataka i statističkih istraživanja, koja su više rutinska i razmatrana je vrijednost informacija o ljudskim resursima koje pospješuju konkurentsku poziciju organizacije i sistemsko donošenje odluka. Primjeri potencijalnih aplikacija su navedeni u pogledu podataka koji su obično „zarobljeni“ u informacionim sistemima o ljudskim resursima.

Cljučne riječi: Data mining, ljudski resursi, informacioni sistemi za ljudske resurse, data mart, donošenje odluka

Abstract: The work deals with the issues of contributions that Data mining (data exploring) could make within the human resource function in organizations. We first provide a basic introduction into techniques and data mining processes (DM) and a survey of the literature with the steps how to explore this information. We also discuss the importance of data keeping (warehousing) and datamart considerations. It has been performed comparing of the contrast between data mining and results of statistical studies, which are more routine, and the value of human resource information which enhance a organization's competitive position and systematic decision-making. Examples of potential applications are outlined in terms of data that is ordinarily "captured" in human resources information systems..

Keywords: Data mining, human resources, human resource information systems, datamart, decision-making

1. UVOD

Uloga stručnjaka za ljudske resurse u organizacijama je evoluirala paralelno sa napretkom u oblasti poslovnih tehnologija. Stručnjaci za ljudske resurse su sada u mogućnosti da posvete više vremena za strateške poslovne odluke, pošto je razvoj tehnologije omogućio automatizaciju mnogih transakcionog procesa u ovoj oblasti. Dok stručnjaci za ljudske resurse više nemaju potrebu za ručnom obradom podataka ipak ne bi trebali da napuste prikupljanje podataka o zaposlenim u organizaciji. Podaci o ljudskim resursima koji su dostupni u okviru jedne organizacije imaju potencijal da potpomognu proces donošenja odluka. Izazov je u identifikaciji korisnih informacija u ogromnim bazama podataka o ljudskim resursima koje su rezultata automatizacije transakcionih proces koje se tiču ljudskih resursa.

Data mining se može smatrati kao evoluirani pristup analizi podataka u veoma velikim bazama podataka koji može postati koristan alat za stručnjake u području ljudskih resursa.

Data Mining uključuje proširenje znanje na bazi obrazaca podataka u veoma velikim bazama podataka. Ipak, data mining ide izvan vršenja jednostavne analize velikih grupa podataka. Organizacije koje zapošljavaju na hiljade radnika i prate mnoštvo informacija vezanih za zapošljavanje mogu da pronađu vrijedne obrasce sa informacijama koje su sadržane u njihovim bazama podataka i na taj način može da se obezbedi uvid u oblastima kao što su zadržavanje zaposlenih i kompenzaciono planiranje. U cilju razvijanja razumijevanja potencijalnih data mining informacija o ljudskim resursima u organizacijama, razmatrali smo komparativne prednosti koje ona pruža. Isto tako, razmatrali smo komponente informacionog sistema za ljudske resurse i identifikovanje šanse i slabosti u primjeni data mining tehnika na informacione sisteme za ljudske resurse.

2. IZGRADNJA KOMPERATIVNIH PREDNOSTI NA OSNOVU LJUDSKIH RESURA

Problem modernog čovjeka je nedostatak uvida u cjelinu, kako na području poznavanja ličnosti, tako i na području proizvodnje i stvaranja. Ukoliko je strategija radne organizacije zasnovana na kvalitetu ljudskih resura, te sposobnostima koje su istovremeno reijetke, dragocjene, nezamjenjive i nesavršene onda će to predstavljati osnovu za održivu konkurentsku prednost organizacije (Barni, 1991). Ako je organizacija u mogućnosti da jedinstveno upravlja sa svojom najvrednijom imovinom-svojim ljudima- tada može biti u stanju da se odovoji od svoje konkurencije i izgradi prednost. Boxall (1993) predlaže menadžmentu ljudskih resursa da kreira održivu komperativnu prednost "unajmljujući taletovano razvojno osoblje i sinergizirajući njihov doprinos sa ostalim resursima firme" (Boxal,1993, str.66). Huseli Jackson i Schuler (1997) smatraju investicije u ljudske resurske kao potencijalni izvor komperativne prednosti u njihovoj analizi efektivnosti ljudskih resursa. Međutim, mnoge organizacije imaju nedostatak menadžment know-how ili nedovoljno informacija neophodnih za donošenje strateških odluka koje se tiču ljudskih resursa.

Komperativna prednost je održiva ako druge firme nisu sposobne da angažuju slične kadrove. Upravljanje ljudskim resursima organizacije je često manje podložno imitaciji, jer konkurenti rijetko imaju pristup praksama upravljanja ljudskim resursima organizacije, pošto ove prakse nisu transparentne onima koji se nalaze van kompanije (Pfeffer, 1994). Iz ovog razloga, efektivno upravljanje ljudskim resursima pruža organizacijama jedinstvenu priliku da uspostave održivu komparativnu poziciju. Svaki korak u razvoju ljudskih resursa uključuje planiranje. Planiranje ljudskih resursa se odvija paralelno sa strateškom planiranjem organizacije. Kada organizacija razvija svoju strategiju mora razmotriti sposobnosti svog osoblja da sprovedu tu strategiju. Kada organizacija identifikuje svoju strategiju, ljudski resursi moraju tada osigurati uspjeh strategije osiguravajući da potebni ljudski resursi budu na pravom mjestu. Ljudski resursi moraju prikupljati, pohranjivati i analizirati informacije u cilju pokretanja planskih procesa naprijed. Razvoj ljudskih resursa je u mnogim strategijama strateški cilj.

Sve organizacije prikupljaju podatke o svojim zaposlenim. Međutim, akcije koje se pokreću povodom toga variraju između različitih organizacija. Neke organizacije koriste te podatke samo za izvršavanje određenih administrativnih poslova. Druge transformišu podatke u korisne informacije za podršku u procesu donošenja odluka (Kovach i Catheart, 1999). Korištenje podataka o ljudskim resursima tokom procesa odlučivanja pomaže organizaciji da donese strateške odluke. Ako organizacija može izvući korisne ili jedinstvene informacije o ponašanjima i potencijalu svojih ljudi iz podataka o ljudskim resursima, to može doprinijeti u procesu donošenja strateških odluka. Drugi tip informacija koje organizacija može tražiti je evaluacija efektivnosti svojih praksi upravljanja ljudskim resursima. Na primjer, često

organizacija implementira «izvor regrutovanja» ili trening program bez jasne metode kako izvršiti te prakse. Analiza podataka prikupljenih tokom implementacije i upravljanja praksama ljudski resursa može obezbijediti drugi resurs za ljudske resurse - a tiče se procesa donošenja odluka.

3. INFORMACIONI SISTEM ZA LJUDSKE RESURSE

Mnoge organizacije u današnje vrijeme su kupile ili napravile baze podataka u cilju prikupljanja, upravljanja i povlačenja podataka koji se odnose na ljudske resurse. Informacioni sistem u oblasti ljudskih resursa ima dvostruku ulogu. Prva uloga (cilj) je administrativne prirode, u svrhu izvršavanja osnovnih transakcija ljudskih resursa kao što su isplata ličnih dohodaka, doprinosa i naknada, izvještavanja rukovodstva i sl. Druga svrha je da podrži organizacioni proces donošenja odluka (Kovach i Catheart, 1999). Informacioni sistem je često veoma skupa investicija za organizaciju, te je sposobnost korišćenja prikupljenih podataka izvan administrativnih potreba može poslužiti kao opravdanje za investiciju.

Informacioni sistem za ljudske resurse u većini organizacija danas počivaju na relacionim bazama. Da bi se mogla kvalifikovati kao relaciona, baza podataka mora da realizuje relacioni model, što je način na koji se opisuje određeni aspekt stvarnog svijeta, u skladu s pravilima koje je definisao dr E. F. Codd kasnih šezdestih godina. Osnovni pojmovi relacionog modela koje je Codd preuzeo iz matematičke teorije skupova su: domen, relacija i atribut. Ovo omogućuje da podaci bude pohranjivani u odvojenim fajlovima koji se mogu povezati preko zajedničkih elemenata kako što su ime ili indentifikacioni broj. Relacione baze podataka obezbjeđuju organizaciji sposobnost da održavaju virtualnu neograničenost količina podataka o zaposlenima. To također dozvoljava organizaciji da pristupi podacima na više različitih načina. Na primjer, organizacija može povući podatke o određenom zaposlenom ili može povući podatke o određenoj grupi zaposlenih kroz sprovođenje pretrage zasnovane na određenom parametru kao što je klasifikacija poslova. Razvoj relacionih baza podataka u organizaciji zajedno sa napretkom u tehnologiji pohrane podataka rezultirao je da organizacije prikupljaju veliki broj podataka o zaposlenim.

Tabela 1 ističe neke primjere tipova podataka koji mogu biti prikupljeni i pohranjeni u IS. Tabela 2 ističe neke tipične funkcionalne upotrebe podataka.

Tabela 1: Podaci prikupljeni u IS

Podaci o zaposlenima	Organizacija/posao podaci
Ime	Rezultati testa prije zaposlenja
Jedinstveni matični broj	Naziv radnog mjesta
Datum rođenja	Stepen radnog mjesta
Pol	Pogodnosti
Bračni status	Ocjena radne uspješnosti
Adresa	Promotivna istorija
Telefonski broj, e-mail	Dosije korektivnih akcija
Kontakt	Informacije o prisustvu
Obrazovanje	Dosijei o obuci
Socijalni status	

Tabela 2: Funkcionalna upotreba podataka prikupljenih u IS

Funkcije korištenja podataka	Redovno generisani i Ad Hoc izvještaji
Kompenzacije i beneficije	Isplata ličnih dohodaka
Zdravlje i sigurnost	Troškovi beneficija
Radna uspješnost	Izborna efektivnost
Obrazovanje i razvoj	Predviđanje ponude/potražnje
Podaci o prethodnom zaposlenju	Istorija transakcija
Izbor i raspoređivanje	Realizovana obuka
Radni odnosi	Analiza negativnog uticaja

Svaka organizacija prikuplja različite vrste podataka koji se odnose na zaposlene. Međutim, gore navedeno će služiti kao primjer tipova podataka koja se prikupljaju i tipične upotrebe tih podataka.

Organizacije takođe koriste podatke skladištene u njihovom IS za pravljenje kalkulacija za evaluaciju finansijskog uticaja njihovih praksi iz oblasti ljudskih resursa. Funkcije ljudskih resursa koriste ovaj tip informacija da podrže kontinuirani razvoj programa ljudskih resursa i takođe da demonstriraju menadžerima kako mogu upravljati ljudskim resursima od momenta njihovog angažovanja. Neki primjeri ovih vrsta kalkulacija su plate i naknade kao procenat operativnog troška, cijena po angažovanom, povrat od treninga i troškovi obrta (Fitz-Enz, 1998).

Dok su ove kalkulacije pogodne za kvantitativni prikaz vrijednosti praksi ljudskih resursa, uticaj praksi kontinuiranog praćenja je malo drugačiji. Može se izvršiti evaluacija troškova po angažovanom, i da li ta informacija pruža neke podatke o vrijednosti tog angažovanog? Da li će doći do povećanja vrijednosti i kvaliteta koje pruža zaposleni u dužem vremenskom periodu? Većina analiza podataka preuzetih iz IS ne pruža mogućnost traženja dodatnih odnosa osim onih za koje koji sistem je prvobitno dizajniran da identifikuje.

4. DATA MINING

Tradicionalni metodi analize podataka često uljučuju ručni rad i interpretaciju podataka koja je spora, skupa i visoko subjektivna (Fayyad, Piatsky-Shapiro i Smyth, 1996). Na primjer, ako su stručnjaci za ljudske resurse zainteresovani za analizu troškova obrta, oni moraju da pribavljaju podatke iz nekoliko različitih izvora. kao što su računovodstveni izvještaji, izvještaji o prekidu i personalna dosijea zaposlenog. Ti podaci se onda kombinuju, povezuju i evaluiraju. Ovaj proces je veoma često podložana greškama. Kako su poslovne baze podataka porasle po veličini, tradicionalni pristup je postao sve više nepraktičan. Data mining je proces za uzimanja podataka iz velikih skupove podataka kroz korišćenje algoritama i tehnika iz oblasti statistike, mašina za učenje i upravljanja bazama podataka. (Feelders, Daniels i Holsheimer, 2000). Data mining se uspješno primjenjuje u mnogim funkcionalnim oblastima kao što su finansije i marketing. IS aplikacije u mnogim organizacijama pružaju, za sada još uvijek neiskorištenu priliku, za primjenu data mining tehnika. Ti sistemi uglavnom sadrže veliku količinu podataka - uslov za data mining. Dok većina aplikacija pruža mogućnost za generisanje adhoc ili standardizovanih izvještaja iz specifičnih skupova podataka.

U nekim aspektima, data mining se može posmatrati kao skup veoma sofisticiranih upita koje podrazumijevaju uzorkovanje i statističko modelovanje. U svakom slučaju, dodatne mogućnosti i koristi upita treba da se uključi u odluke o dizajniranju skladišta podataka, ili datamart za data mining upotrebu.

Aplikacije sistema podrške za donošenje odluka (Decision support system) mogu se posmatrati kao prethodnica data mining aplikacija. Decision support system aplikacije su alati

koji dozvoljavaju prikupljanje podataka iz baza podataka, analizu podataka i predstavljaju analizu u mnogim formama, kao što su grafikoni i izvještaji. Ovi sistemi mogu koristeći statističke pakete modelovanja za analiziranje podataka dovesti do informacija za podršku pri odlučivanju u organizaciji. Ovi sistemi mogu kombinovati informacije iz drugih funkcionalnih oblasti u okviru organizacije, kao što su usluge potrošačima i marketing, da pruže podršku donošenju odluka iz oblasti upravljanja ljudskim resursima (Broderick i Boudreau, 1992). Na primjer, korisnik može izgraditi statistički model za analizu podataka kao što je potrebno vrijeme za ispunjavanja zahtjeva za uslugom i vrijeme za isporuku usluge, pošto su one u vezi sa stepenom zadovoljstva potrošača. Informacije dobijene ovom analizom kasnije se mogu koristiti za uspostavu ciljeva postignuća pred zaposlene. Dok Decision support system aplikacije mogu obezbijediti korisne informacije za donosiocje odluka u organizaciji, moraju se uspostaviti veoma specifični planovi analiza. Od velike je važnosti da korisnik zna koji odnosi postoje prije same analize podataka. Dalje, nekoliko iteracija modela može da se testira prije same identifikacije korisnih informacija.

Za data mining, najvažnije je da svi podaci budu dostupni u razumno lakom okruženju i da se specifična pitanja ne moraju uvijek precizno znati. Data mining teži da se ide dalje od običnih statističkih izvještaja koji prikazuju samo ono što jeste. Data mining ima za cilj da se sazna više o tome kako i zašto (kauzalnost). Naši pokušaji u primjeni data mininga u predviđanju uspjeha na univerzitetu i kriranje upisne politike su još u rudimentalnom obliku (Simeunović, 2010). Slično ovom primjeru postoje pokušaji u organima upravljanja lokalnih zajednica, da se sistem upravljanja ljudskim resursima zasnovan na dostignućima i rezultatima istraživanja različitih nauka u ovoj oblasti. Prvi korak u ovome postupku je određivanje lica koje bi se bavilo pitanjima ljudskih resursa. Drugi korak je nabavka adekvatne opreme i nabavka softvera za praćenje promjena u upravljanju ljudskim resursima. Ukoliko nabavljeni softver ne odgovara potrebama, tj. ukoliko se na početku ne definišu varijable i jasne potrebe može se dogoditi da se ovom problemu i dalje pristupa na tradicionalan način, bez puno koristi za menadžment u smislu donošenja odluka. Razlozi za ovakvo stanje se mogu razvrstati u nekoliko grupa i to:

- mnogi koji donose odluke u organizacijama ne znaju za sve pogodnosti koje pruža data mining u oblasti odlučivanja,
- službe za IT u organizacijama pokušavaju opravdati svoju ulogu pravljenjem programa za upravljanje ljudskim resursima, koji se najčešće zasnivaju na deskriptivnoj statistici,
- relativno slabo poznavanje tehnika koje omogućuju skladištenje podataka,
- još uvijek nedovoljno razvijena svijest o potrebi upravljanja ljudskim resursima, kao glavnom činiocu razvoja u 21. vijeku.

5. SELEKCIJA I PREDHODNA OBRADA PODATAKA

Selekcija i priprema podataka je važan korak u data mining procesu. Neke organizacije imaju nezavisne informacione sisteme za ljudske resurse koje odlikuju multiplicirane baze podataka koje nisu povezane među sobom. Ovaj tip sistema je ponekad odabran da ponudi veću fleksibilnost udaljenim organizacionim jedinicama ili podgrupama sa jedinstvenim informacionim sistemom (Anthony, Perrewé i Kacmar, 1996). Moguća nekonzistentnost pri izradi baza podataka može učiniti data mining teškom u slučajevima postojanja multipliciranih baza podataka. Skladištenje podataka može spriječiti ovaj problem i preporučuje se da organizacija oformi skladište podataka prije nego što započne sa data mining projektom. Ipak, ova vrste uređivanje se ne može sasvim izbjeći i na sličan način predstavljaju korak u razvoju skladišta podataka, ili datamart. Prednost stečena u tome što se

prvo razvija skladište podataka ili mart je u tome što je većina posla u vezi sa uređivanjem podataka urađena već na početku.

Jedan od najvećih problema sa kojim se suočava data mining su nedostajući podaci, ali i podaci koji su skladišteni bez jasnog plana o njihovoj stvarnoj upotrebi. Ovo je posebno tačno ako se radi o informacijama o ljudskim resursima. Obično kada se prikupljaju podaci o ljudskim resursima, cilj je neka vrsta administrativne potrebe, kao što su obrade plata ili obračun radnog staža isl.. Potreba za podacima za zahtjevane transakcije je samo u cilju razmatranje koji tip podataka će se prikupljati. Buduće analize potreba i vrijednosti u podacima koji su prikupljeni se obično ne razmatraju. Nedostajući podaci takođe mogu biti problem, posebno ako administrator sistema nema kontrolu nad unosom podataka. Mnoge organizacije su iskoristile prednosti mrežnih tehnologija da dozvole zaposlenima da sami unose i ažuriraju vlastite podatke (McElroy, 1991). Zaposleni mogu izabrati da ne unose određene podatke što će kao rezultat imati nedostajuće podatke. Međutim, skladište podataka ili data mart može pomoći da se spriječi manipulisanje podacima jer sistem ne dozvoljava unošenje određenog obrasca bez svih potrebnih podataka. Na ovaj način sve potrebne varijable i atributi koji opisuju date varijable su uvijek dostupni za analizu.

Kod razvoja skladištenja podataka uvijek se moraju učiniti neki kompromisi i to:

- koji od podataka izabrati i sačuvati u skladištu podataka kada se zna da previše podataka produžava vrijeme razvoja IS, a premalo podataka postavlja pitanje svrsishodnosti sistema,
- kako raditi sa podacima kojima nedostaje određena vrijednost (Suknović, Delibašić, 2010. str. 50).

Da bi se mogla primijeniti neka od tehnika data mininga potrebno je definisati skladište podataka što znači da su:

- riješena pitanja neispravnih formata podataka,
- riješena su pitanja neispravnih vrijednosti podataka,
- riješena su pitanja nedostajućih vrijednosti podataka (ili su redovi izbačeni iz analize ili su zamijenjeni nekim vrijednostima),
- podaci su stavljeni u ispravne relacije, tako da se mogu uspješno povezati.

6. ANALIZA I INTERPRETACIJA

Postoji mnogo tipovi algoritama u upotrebi u data miningu koji služe za analizu podataka. Izbor algoritma zavisi od namjeravane upotrebe dobijenih rezultata (Bredley, Lane i Stough, 1999). Ciljevi data mininga mogu se podijeliti u dvije glavne kategorije. Neke aplikacije traže verifikaciju hipoteza formulisanih od strane korisnika. Drugi cilj je otkrivanje ili razotkrivanje novih obrazaca na sistemski način (Fayyad, Piatsky-Shapiro i Smith, 1996). Tokom otkrivanja, podaci mogu biti korišćeni ili da se predvidi buduće ponašanje ili za opis obrazaca u razumljivoj formi. Ipak, potpuna diskusija o tehnikama data miningu izlazi iz okvira navedenog u ovom poglavlju. Predstavićemo neke tehnike koje bi mogle da se koriste u analizi ljudskih resursa.

Klasteri i klasifikacija su primjer skupa data mining tehnika pozammljenog iz klasičnih statističkih metoda koje nam pomažu da objasnimo obrazce u informacijama. Grupisanje (klasteri) ima za cilj da identifikuje mali skup iscrpnih i međusobno isključivih kategorija za opisivanje prisutnih podataka. Ovo može biti korisna primjena informacija o ljudskim resursima ako organizacija pokušava da identifikuje određeni skup zaposlenih sa konzistentnim atributima. Na primer, poslodavac može da poželi da sazna koje su glavne kategorije vrhunskih ekonomista u njegovoj organizaciji, imajući na umu različite programe za te grupe u cilju poboljšanja efikasnosti poslovanja. Na osnovu dobijenih podataka poslodavac

može odlučiti da jednu grupu uputi na dodatno sticanje znanja iz stranih jezika, drugu grupu na izučavanje savremenih propisa u oblasti obračuna poreza itd. Teškoća sa tehnikom grupisanja je u tome što nisu poznate normativne tehnike koje određuju tačan broj klastera koji treba da se formiraju. Pored toga, postoji veliki broj različitih logika koji se mogu poštovati prilikom formiranja klastera. Iz tog razloga, vještina analitičara je presudna. Slično tome, klasifikacija je data mining tehnika koja "otkriva modele koji povezuju ulazne attribute sa izlaznim kategoričkim atributima" (Suknović, Delibašić, 2010. str.82). Klasifikacija može biti korisna u ljudskim resursima za klasifikaciju trendova ili kretanja kroz organizaciju za određene grupe uspješnih. Organizacija je u prednosti kad prilikom zapošljavanja može ponuditi realističan put karijere za novo zaposlene. Biti u stanju da se prikaže putanja karijere sa informacijama koje održavaju uspjeh zaposlenog, može da bude snažan resurs za one koji su zaduženi za zapošljavanje u organizaciji.

Ako postoji mnogo mjera za neku poželjnu odluku zaposlenog, faktorska analiza može doprineti njihovom smanjenju na nekoliko podesnih faktora. Stabla odlučivanja su vrlo često korištena tehnika u data mining analizi. Tehnika definisanja promjenljivih se zasniva na maksimiziranju razlika ili kontrasta između podataka koji se dijele u grupe. Primjena stabla odlučivanja u upravljanju ljudskim resursima može biti višestruka, a kriterijumi određivanja posmatranih grupa različiti.

Regresija i ostali povezani modeli, koja takođe pozamljuje iz klasične statistike, dozvoljava procjenu linearne funkcije nezavisnih promjenljivih koje najbolje objašnjavaju ili predviđaju datu zavisnu promjenjivu. S obzirom da je ova tehnika dobro poznata, nećemo se zadržavati detaljno je objašnjavajući. Međutim, skladište podataka i data mart može biti toliko veliko da direktna upotreba svih raspoloživih posmatranja je nepraktična za regresiju i slične studije. Dakle, slučajno uzorkovanje može biti neophodno da koristite analizu regresije. Razne nelinearne tehnike regresije su takođe dostupne u komercijalnim statističkim paketima i mogu se koristiti na sličan način za data mining.

Neuronske mreže mogu se posmatrati kao specijalni tip nelinearnih modela regresije. Data mining softver za specijalne namjene uglavnom obezbjeđuje ovu opciju za izgradnju modela. Može se primijeniti na isti način kao regresija u slučaju jedne zavisne promjenljive. Međutim, neuronske mreže imaju dodatnu fleksibilnost da rade sa više od jedne zavisne promjenljive koja treba da se predvidi iz istog skupa nezavisnih promenljivih.

U stvari, bilo koji statistička ili tehnika analize podataka može potencijalno biti korisna za data mining studije. Jedna od preporuka za uspješno korišćenje bilo koje tehnike je dobro poznavanje uzorkovanja. Analiza podataka je nekada mnogo lakša od interpretacije. Interpretacija zahtijeva poznavanje osnovne logike data mininga ali i posjedovanje epistemoloških znanja o varijablama koje se identifikuju. Kad se dobiju neki rezultati potrebna je dalja analiza nekih pitanje da bi se odredila njihova stvarna korist. Ovdje je nužno angažovati što više eksperata iz različitih oblasti. Angažujući specijaliste, organizacija može da obezbedi dostupnost ekspertize. U tabeli 3 smo predstavili neka pitanja koja bi se mogla dobiti metodama data mininga.

Tabela 3: Primjeri pitanja koje su u vezi sa ljudskim resursima

Karakteristike aplikacija potrebne za eventualni uspjeh u organizaciji

Da li postoji veza između povećanog zalaganja i efikasnosti?
Kakav je odnos između stepena zadovoljstva vlastitim statusom u organizaciji i efektivnosti?
Kako sistem ocjenjivanja zaposlenih utiče na njihovu produktivnost?
Da li se određeni obrazovni programi podudaraju sa potrebama organizacije?
Da li postoji zajednička vizija i misija u organizaciji?
Da li postoji odnos između promotivne istorije i dužine usluge?
Da li postoji veza između pojačanog nadzora i učinka?
Da li postoji veza između samoinicijativnosti i uspjeha?
Koliki je stepen posvećenosti zaposlenih realizaciji strateških ciljeva?
Kako međuljudski odnosi utiču na stepen realizacije određenih zadataka?
Kakav uticaj ima timski rad i planiranje na efikasnost organizacije?
Kako sistem donošenja odluke utiče na efikasnost zaposlenih?

Nakon što je prikladna ekspertiza dostupna, sledeći korak je formulisanje pitanja koje bi data mining trebalo da istraži. Postoji mnogo pitanja na koje bi stručnjaci za ljudske resurse i menadžment kompanije želili da dobiju odgovore. Tabela 3 pruža nam neke primjere pitanja koje organizacije mogu smatrati važnim u njihovom poslovanju. To su pitanja na koje IS i data mining mogu pružiti odgovor. Ovo je samo par primjera dok su mogućnosti velike. Od velike važnosti je način upotrebe podataka dobijene u procesu data mininga. Lica koja se bave ljudskim resursima trebaju biti osposobljena da iz velikog broja podataka koji se dobija u procesima analize i interpretacije izdvoje one podatke koje bi najviše mogli doprinijeti u procesu donošenja adekvatnih odluka menadžerskog tima. Greške u ovom procesu imaju nesagledive posledice, te je poštovanje principa etičnosti nužno.

7. ZAKLJUČAK

Data mining pruža široke mogućnosti u korišćenju skrivenih veza i relacija u podacima koji se nalaze u bazama podataka. U procesu primjene data mininga u oblasti ljudskih resursa nužno je ispoštovati sve neophodne korake, tek tada upotreba određenih tehnika dobija pravi smisao. Prvi korak uvijek predstavlja donošenje prave odluke o korišćenju pogodnosti IS u oblasti upravljanja ljudskim resursima. Drugi korak je izbor lica koja se bave ovom problematikom. Treće je definisanje baze podataka i skladišta podataka. Na kraju je uvijek obrada, interpretacija i upotreba dobijenih rezultata. Ono što se može smatrati posebno važnim odnosi se na sistem upita koji se daju data miningu. Od kvaliteta upita zavisi i konačan rezultat date analize. Vrijeme u kojem živimo će nužno zahtijevati naučan pristup najvažnijem resursu 21. vijeka – ljudskom resursu (znanju).

LITERATURA

- [1] Agosta, L. (2000). The essential guide to data warehousing. Upper Saddle River. NJ: Prentice Hall PTR.
- [2] Anthony, W.P., Perrewé, P.L. (1996). Strategic human resource management. Orlando, FL: Harcourt Brace Company.
- [3] Barney, J. (1991). Firm resources and sustained competitive advantage. Journal of Management, 35, 99-120.
- [4] Broderick, R., Boudreau, J.W. (1992). Human resource management, information technology, and the competitive edge. Academy of Management Executive, 6, 7-17.
- [5] Milosavljević, M. (2005). Neuronske mreže, Elektrotehnički fakultet, Beograd.
- [6] Fayyad, U.M., Piatsky-Shapiro, G., Smyth, P. (1996). From data mining to knowledge discovery in databases. AI Magazine, (7), 37-54.

- [7] Feelders, A., Daniels, H., Holsheimer, M. (2000). Methodological and practical aspects of data mining. Information Management, (37), 271-281.
- [8] Simeunović, V. (2010). Primjena data mininga za predviđanje uspjeha u studiranju, Pedagoški fakultet, Bijeljina.
- [9] Suknović, M., Delibašić, B. (2010). Poslovna inteligencija i sistemi za podršku odlučivanju, FON, Beograd.