Damir Ravlić[1]

PRIMJENA MODELA PODATKOVNE KOCKE U FUNKCIJI POBOLJŠANJA PROGNOZE UVOZA I IZVOZA

SAŽETAK

Jedan od problema upravljanja je nedostatak kvalitetnih podataka. To ne znači da oni ne postoje nego, naprotiv, najčešće smo zatrpani nepotrebnim podacima. Problem je kako iz takve mase podataka izdvojiti bitne za donošenje odluka. Podaci su dio aktive poduzeća i zajedno s kapitalom i ljudskim resursima bitan su dio ukupne kompetitivnosti. Različiti softverski alati za gradnju sustava za potporu odlučivanju omogućuju analize, a osobito one za prognoziranje vodećih ekonomskih indikatora.

Rad prikazuje primjenu jedne od suvremenih metoda transformiranja podataka u poslovnu inteligenciju, tj. kako učinkovitije iskoristiti raspoložive podatke. Poslovna inteligencija je upravo takav proces koji nedostaje velikom broju organizacija, a kojim se nastoje dobiti potrebne informacije iz raspoloživih podataka. Takvi primarni podaci o transakcijama jasan su pokazatelj stanja, jasan pokazatelj što se događa u organizaciji. Oni ne daju jasan odgovor zašto se nešto događa, ne dijagnosticiraju procese i promjene, ne interpretiraju rezultate, ne klasificiraju podatke, ne određuju klastere, ne modeliraju ovisnosti među podacima, ne otkrivaju promjene ni odstupanja u odnosu na postavljene ciljeve, ne određuju korelaciju između podataka, ne generiraju asocijativna pravila ili korelacije između slogova u bazama. S transakcijskim podacima neposredno ne možemo dati odgovore na naprijed postavljena pitanja.

[1] **Mr.sc. Damir Ravlić,** Federalno ministarstvo obrazovanja i znanosti, Dr. Ante Starčevića bb, Mostar, Bosna i Hercegovina, e-mail: damir.ravlic@fmon.gov.ba; damir.ravlic@tel.net.ba

[1] OLAP – Kategorija softverskih alata koji omogućuju analizu podataka smještenih u bazu podataka. OLAP alati korisniku omogućuju analizirati različite dimenzije multidimenzijskih podataka, npr. omogućuju rad s vremenskim serijama i analizu trenda. Glavna komponenta OLAP-a je OLAP poslužitelj koji je «smješten» između korisnika i sustava za upravljanje podacima (DBMS).

Skladištenje podataka, on-line analitička obrada (OLAP) i otkrivanje znanja u skladištima i bazama podataka najznačajnije su i najvažnije nove tehnologije u području poslovne obrade podataka. Integracije informatičkih alata i odgovarajućih kvantitativnih i kvalitativnih modela odlučivanja rezultiraju novim tipovima informacijskih sustava za potporu odlučivanju (od izvršnih informacijskih sustava, strategijskih informacijskih sustava do inteligentnih sustava za potporu odlučivanju).

U ovome se radu istražuje kako modeli podatkovne kocke i modeli odlučivanja «surađuju» na primjeru prognoziranja uvoza/izvoza.

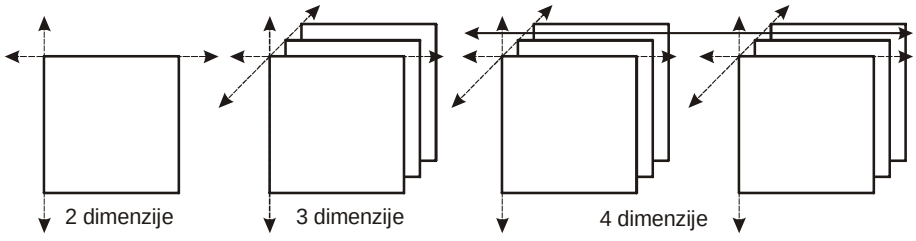
Ključne riječi: Podatkovna kocka, OLAP, poslovna inteligencija, sustavi za potporu odlučivanju, prognoziranje uvoza/izvoza.

JEL: C53, C88

1. Model podatkovne kocke i modeli odlučivanja

Središnji dio koncepta OLAP-a je multidimenzijski pregled podataka. Stavka «dimenzija» je kategorija podataka i uvijek je povezana s brojčanom vrijednošću nazvanom «mjera». Zbog potreba menadžera za informacijom potrebno je stvoriti multidimenzijsku tablicu podataka koja će reflektirati posebne poglede menadžera prema podacima. Jednostavan način vizualizacije multidimenzijskih podataka je proračunska tablica (spreadsheet). Dodavanjem nove vrijednosti dodajemo treću dimenziju pregledu podataka i takva nova struktura podataka je poznata kao podatkovna kocka. Nastavimo li dodavati nove dimenzije, tada se pregled (vizualizacija) ovoga postupka prikazuje kao na Slici 1.1.

Slika 1.1. Multidimenzijski pregled podataka



Na primjeru će biti prikazano kako modeli podatkovne kocke (koji osiguravaju donositelju odluke činjenice o problemu odlučivanja koji želi riješiti) i modeli odlučivanja (koji su uvijek pojednostavljene prezentacije realnog sustava), «surađuju» na primjeru prognoziranja uvoza/izvoza. Model prognoziranja uvoza i izvoza koji je odabran, eksponencijalno je poravnavanje (izglađivanje).

2. Metode prognoziranja uvoza i izvoza

Kako bi se izabrala najbolja metoda prognoze, prvo će biti objašnjena konceptualna razlika između dvaju osnovnih modela kvantitativnih metoda prognoziranja: time-series (metoda vremenskih serija) i explanatory (opisna metoda) (Makridakis&Wheelwright, 1989).

Modeli prognoziranja sastoje se od procedura koje koristi ta tehnika u razvitku prognoziranja. Veliki je raspon modela prognoze koji se mogu koristiti, ali za kvantitativne metode odabir modela vrši se između dvije prilično dobro definirane kategorije.

Prvi je tip kvantitativnog modela prognoze, koji se najčešće i koristi, model vremenskih serija (time-series). U tom modelu bitna su dva čimbenika: nizovi podatka za prognozu i vremenski interval koji će se koristiti.

Tip vremenskih serija je model koji uvijek podrazumijeva ponavljanje pravilnosti i veze među podacima (pattern) ili njihove kombinacije tijekom vremena. Identificiranjem i ekstrapolacijom tih pravilnosti i veza među podacima mogu biti razvijene prognoze za uzastopne vremenske intervale.

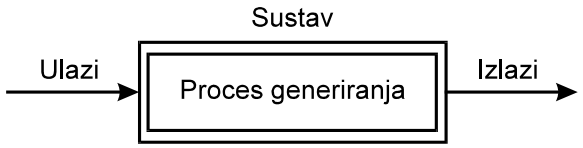
Bilo koja metoda prognoziranja koja koristi model vremenskih serija kao rezultat će dati istu prognozu za sljedeće razdoblje, bez obzira koju je aktivnost menadžer poduzeo.

Model vremenskih serija može biti pogodan za prognozu čimbenika okruženja, kao što su opća ekonomija i razina zaposlenosti, gdje individualne odluke imaju malo utjecaja, ali nije pogodna za prognozu mjesečnih prodaja koje su rezultat promjena u cijenama i reklamiranju.

Jedna od prednosti modela vremenskih serija je da su osnovna pravila računanja orijentirana prema uzastopnim vremenskim intervalima. To znači da su podaci u većini tvrtki raspoloživi na temelju tih razdoblja i mogu biti korišteni u aplikacijama koje koriste prognoziranje metodom vremenskih nizova.

Prognoza metodom vremenskih serija tretira sustav kao «crnu kutiju» (black box) i ne pokušava otkriti čimbenike koji utječu na njegovo ponašanje. Kao što je prikazano na Slici 2..1. sustav je jednostavno prikazan kao nepoznati proces generiranja. (Sustav može biti bilo što – nacionalna ekonomija, prodaja proizvoda tvrtke...)

Slika 2.1. Odnosi/veze vremenskih serija



Tri su osnovna razloga za tretiranje sustava kao «crne kutije». Prvo, sustav može biti nerazumljiv i čak, ako je razumljiv, može biti vrlo teško mjeriti odnose/veze (relationships) u smislu upravljanja njihovim ponašanjem. Drugo, osnovna briga može biti samo predvidjeti što će se dogoditi, a ne zašto. Treće, mala je korist, a troškovi saznavanja zašto se nešto događa, kao i predviđanja istog, mogu biti vrlo visoki, dok troškovi korištenja metode vremenskih serija mogu biti relativno niski.

Dugi tip kvantitativne metode prognoziranja je opisni. Kod tih metoda bilo koja promjena ulaza utjecat će na sustav na predviđeni način, pretpostavljajući da su relacije konstantne. Prva zadaća prognoze je odrediti odnose/veze promatrajući izlaz sustava (ili kroz vremensku seriju ili proučavajući presjek sličnih sustava) i povezujući ih s odgovarajućim ulazima. Primjerice, jedna od zadaća može biti određivanje relacija u sustavu kako bi se prognozirali izlazi kao što je bruto nacionalni proizvod, vrijednosti prodaje itd.

Takav proces, ako se izvede korektno, omogućit će procjenu tipa i intenziteta odnosa između ulaza i izlaza. Ti odnosi mogu biti korišteni za prognozu budućih stanja sustava, osiguravajući poznate ulaze za buduća stanja sustava.

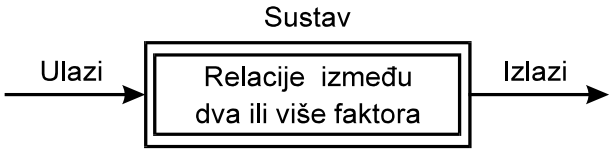
U osnovi, opisna (explanatory) metoda pretpostavlja da su vrijednosti određenih promjenjivih (izlazi) funkcija jedne ili više promjenjivih (ulazi). U užem smislu model vremenskih serija može se smatrati opisnim modelom, sve dok se tekuće vrijednosti smatraju funkcijom same vremenske serije. Pojam «opisni model», međutim, u općem je slučaju rezerviran za modele s promjenjivima drukčijim od vremena. Primjer bi mogao biti jednadžba za predviđanje prodaje koja temelji svoju prognozu na vrijednostima cijena i reklame u okviru kompanije i industrije, tj. jednadžba bi glasila da je prodaja funkcija tih promjenjivih. Prava snaga opisnog modela kao metode prognoze je da menadžer može razviti opseg prognoza u ovisnosti o opsegu vrijednosti za različite ulazne promjenjive. Međutim, bit tih metoda je da one zahtijevaju informacije o nekoliko promjenjivih kao dodatak promjenjivim koje se prognoziraju. Kao rezultat, njihovi su zahtjevi za podacima mnogo veći nego u metodi vremenskih serija. Budući da opisni modeli ovise o nekoliko čimbenika, njima treba više vremena da se razviju i oni su osjetljiviji na promjene u relacijama čimbenika nego

modeli vremenskih serija. Dalje, oni zahtijevaju procjenu budućih vrijednosti ulaznih čimbenika prije nego izlazne vrijednosti mogu biti prognozirane.

Budući da su vrijednosti uvoza i izvoza neki od čimbenika koji utječu na bruto društveni proizvod države (Gross National Product - GNP), njihova prognoza izravno utječe na smjernice makroekonomske politike.

Prognoza uvoza i izvoza ne može se promatrati zasebice. Kako bi se provela kvalitetna ulazno-izlazna (input-output) analiza, ona se mora promatrati u ovisnosti i kombinaciji s drugim čimbenicima koji utječu na vođenje makroekonomske politike.

Slika 2.2. Opisne ili ovisne relacije



Ekonomske aktivnosti mogu biti prognozirane otkrivanjem i mjerenjem relacija nekoliko čimbenika koji utječu na bruto društveni proizvod, kao što su monetarna i fiskalna politika, inflacija, potrošnja (capital spending) i uvoz i izvoz, dakle:

[2.1.] GNPt+1 = f (monetarne i fiskalne politike, inflacije, potrošnje, uvoza, izvoza)

gdje f znači funkcija od, ovisi o, pod utjecajem od, što znači da bruto društveni proizvod ovisi o, ili je određen čimbenicima s desne strane jednadžbe. Kako se ti čimbenici mijenjaju, GNP varira na način specificiran oblikom odabranog modela.

Ako je jedina svrha prognoza budućih vrijednosti GNP, ne vodeći računa hoće li biti realizirana određena razina GNP-a, bila bi prikladna metoda vremenskih serija (time-series). Poznato je da se veličina GNP-a ne mijenja drastično od jednog mjeseca do drugog, ili čak od jedne do druge godine. Tako će GNP sljedećeg mjeseca ovisiti o GNP-u prethodnog mjeseca i vjerojatno o prethodnim mjesecima. Na temelju toga promatranja, GNP može biti predstavljen kako slijedi:

[2.2.] GNPt+1 = f (GNPt , GNPt-1 , GNPt-1 , GNPt-3 , ...)

gdje je: GNPt - GNP tekućeg mjeseca

GNPt+1 - GNP u sljedećem mjesecu (prognozirani)

GNPt-1 - GNP posljednjeg (prethodnog) mjeseca

GNPt-2 - GNP pretposljednjeg mjeseca itd.

Predstavljeni model je sličan opisnom, izuzev što su čimbenici s desne strane jednadžbe prethodne vrijednosti onima s lijeve strane sve do trenutka kada model ne zahtijeva posebno unošenje ulaznih (input) vrijednosti.

Međutim, za oba navedena modela neophodno je da su relacije između lijeve i desne strane jednadžbi otkrivene i izmjerene, tako da mogu biti ekstrapolirane u svrhu prognoze.

2.1. Tipovi pravilnosti i veza među podacima vremenskih serija (time-series data)

Postoje četiri osnovna elementa ili komponente pravilnosti i veza među podacima: horizontalni, sezonski, ciklični i trend (Makridakis&Wheelwright, 1989).

Horizontalne pravilnosti i veze među podacima postoje kada nema trenda u podacima. Kada je to slučaj, vremenske se serije smatraju stacionarnim, tj. nema trenda u povećanju ili smanjenju kroz razdoblja na bilo koji sustavan način. Tako će sljedeća vrijednost razdoblja biti iznad ili ispod srednje vrijednosti. Takav se slučaj javlja kod proizvoda sa stabilnom prodajom, broja neispravnih proizvoda u stabilnom proizvodnom procesu ili kod prodaje u kratkim razdobljima.

Sezonske pravilnosti i veze među podacima postoje kada se one mijenjaju periodično prema nekom sezonskom čimbeniku. Sezone mogu biti mjeseci ili četiri godišnja doba, ali i sati u danu, dani u tjednu ili dani u mjesecu. Takve pravilnosti i veze među podacima postoje zbog različitih razloga, od toga kako je tvrtka odlučila obaviti određene poslove, do vanjskih čimbenika kao što su vremenski uvjeti. To se javlja npr. kod kvarljive robe, loživog ulja i drugih proizvoda ovisnih o vremenskim uvjetima.

Ciklične pravilnosti i veze među podacima su slične sezonskim, ali je duljina pojedinačnog ciklusa uglavnom veća od jedne godine. Mnogi nizovi podataka, kao npr. cijene metala, bruto nacionalni proizvod i podaci o prodaji mnogih

tvrtki, sadrže ciklične pravilnosti. Cikličnu pravilnost je teško predvidjeti jer se ne ponavlja u konstantnim vremenskim intervalima, i njezino trajanje nije jednolično (uniformno).

Trend pravilnost postoji u slučaju povećanja ili smanjenja vrijednosti promjenjive tijekom vremena. Kretanje prodaje mnogih tvrtki, društvenog bruto proizvoda, cijena i mnogih drugih poslovnih i ekonomskih indikatora tijekom vremena prate trend pravilnost.

Iako postoji veliki broj pravilnosti i veza među nizovima podataka, četiri gore navedene su najvažnije. One se mogu pojaviti zajedno (neki nizovi podataka kombiniraju trend, sezonsku pravilnost i cikličnu pravilnost) ili pojedinačno.

2.2. Metode izglađivanja (smoothing methods)

Metode izglađivanja su tehnike prognoziranja koje se koriste za izradu kratkoročnih prognoza za veliki broj različitih točki (item). Tipični primjer bila bi situacija u kojoj menadžer mora uskladiti proizvodnju na temelju neke prognoze za nekoliko stotina različitih proizvoda u proizvodnoj liniji. Kod metode toga tipa, povijesni se podaci koriste za dobivanje «izglađenih» vrijednosti za nizove (serije) podataka. Ta se izglađena vrijednost onda ekstrapolira da bi postala prognoza za buduće vrijednosti skupa podataka. Dva najčešća podskupa metoda izglađivanja su metode prosjeka i eksponencijalne metode izglađivanja. Metode prosjeka odgovaraju konvencionalnoj definiciji prosjeka, jednako vrednujući (ili izglađivajući) brojčane vrijednosti uključene u prosjek. Eksponencijalne metode izglađivanja se primjenjuju na različite veličine vrijednosti niza povijesnih podataka. Te se veličine vrijednosti ponašaju na eksponencijalan način od najniže do najviše vrijednosti podatka. Cilj tih metoda prognoziranja je napraviti razliku između slučajnih fluktuacija i osnovnih pravilnosti i veza među podacima (pattern) «izglađujući» (praveći prosjek) povijesnih (prethodnih) vrijednosti. Ti će iznosi ukloniti slučajnosti otkrivene u povijesnom tijeku događaja i temeljiti prognozu na «izglađenoj» pravilnosti među podacima.

2.3. Eksponencijalne metode izglađivanja

2.3.1. Jednostruko eksponencijalno izglađivanje

Jednostruko eksponencijalno izglađivanje je metoda pogodna za prognoziranje kod vremenskih serija bez trenda i može se izraziti formulom:

$$[2.3.] \quad F_{t+1} = \alpha Y_t + (1-\alpha)F_t, \quad (t = 0, 1, 2, ..., n)$$

gdje je: Ft+1 - novo prognoziranje za sljedeće razdoblje (metodom jednostrukog izglađivanja izračunat prosjek za trenutak t)

Yt - nova stvarna vrijednost

Ft - prethodno prognoziranje

α - konstanta izglađivanja ($0<\alpha<1$)

Gornji se izraz može napisati i u sljedećem obliku:

$$[2.4.] \quad F_{t+1} = F_t + \alpha + (Y_t - F_t)$$

Razlika (Yt - Ft) predstavlja procjenu et, tj. pogreške u prognoziranju, odnosno slučajne fluktuacije. Međutim, praktično se ne zna hoće li se pojaviti ikakva razlika (Yt - Ft) kao posljedica slučajnih fluktuacija, kao ni koliko će to utjecati na promjenu Yt. Zbog toga se kod metode jednostrukog izglađivanja pretpostavlja da se samo dio pogreške u prognoziranju može uzeti za korekciju Yt. Očigledno je da se uporabom te metode prognoziranje za iduće razdoblje dobiva na temelju posljednjeg prognoziranja korigiranog produktom konstante izglađivanja α i pogreške posljednjeg prognoziranja. Metoda izglađivanja «uči» na prethodnim pogreškama, a brzina «učenja» je određena veličinom konstante izglađivanja α. Iako je α definirano na intervalu [0,1], u praksi se vrijednost za α kreće između 0,01 i 0,50. Što je dulje vrijeme prognoziranja, to je veća vrijednost konstante α, zbog veće vjerojatnosti promjena uvjeta tijekom duljeg razdoblja.

Odabir vrijednosti konstante izglađivanja α može se napraviti na nekoliko načina: na temelju tradicije, odnosno, ako je ranije aritmetička sredina bila korištena za prognoziranje, α se određuje ekvivalentno prema zadanom n; na temelju eksperimenta (simulacije) i na temelju iskustava donositelja odluke, minimiziranjem rezidualne pogreške.

Koriste se različiti pokazatelji vezano za postupak iznalaženja minimalnih pogrešaka prognoziranja, a neki od njih su: prosječna apsolutna devijacija, srednja kvadratna pogreška, srednja apsolutna postotna pogreška.

Ipak, u praksi se najčešće koristi drugi korijen iz srednje kvadratne rezidualne pogreške (RMSPE – engleski: Root Mean Square Prediction Error), koja uzima u obzir i srednju vrijednost ($\bar{e}$) i standardnu devijaciju rezidualnih pogrešaka (Se). RMSPE se izračunava sljedećom relacijom [Šilj, 1988.]:

$$[2.5.] \quad RMPSE = \sqrt{\bar{e}^2 + S_e^2}$$

gdje je:
$$\bar{e} = \frac{1}{n}\sum e_i \quad \text{i} \quad S_e = \sqrt{\frac{1}{n-1}\sum (e_t - \bar{e})^2}$$

Metoda dvostrukog eksponencijalnog izglađivanja se prije svega rabi za prognozu kod vremenskih serija koje izražavaju linearni trend. Međutim, svoju primjenu ona nalazi i kod vremenskih serija s nelinearnim trendom jer se one odgovarajućim transformiranjem mogu svesti na linearni trend.

Polazi se od pretpostavke da sljedeći model opisuje podatke kao vremensku seriju:

$$[2.6.] \quad , \; F_{t+1} = F_t + T_t + e \quad (t = 0, 1, 2, ..., n)$$

gdje je T nagib linije trenda za razdoblje t.

Dvostruko eksponencijalno izglađivanje se može predstaviti izrazom:

$$[2.7.] \quad F_{t+1}^{(2)} = \alpha F_t + (1-\alpha) F_{t-1}^{(2)}$$

gdje je: Ft – jednostruko izglađivanje

F(t-1) (2) – dvostruko izglađivanje u prethodnom razdoblju.

2.3.3. Trostruko eksponencijalno izglađivanje

Prognoza za najveći broj nelinearnih vrsta trendova može se svesti na metodu dvostrukog eksponencijalnog izglađivanja. Iznimku čini npr. funkcija koja prvo

postiže maksimum, a zatim dolazi do naglog (eksponencijalnog) pada prema nuli. U tom se slučaju može pretpostaviti da vremenska serija ima sljedeći oblik:

$$[2.8.] \quad F_{t+1} = F_t + T_1 t + \frac{1}{2} F_2 t^2 + e$$

Uporabom izraza za jednostruko i dvostruko eksponencijalno izglađivanje analogno se dobiva i izraz za trostruko eksponencijalno izglađivanje:

$$[2.9.] \quad F_{t+1}^{(3)} = \alpha F t^{(2)} + (1-\alpha) F_{t-1}^{(3)}$$

gdje je: Ft(2) - dvostruko izglađivanje

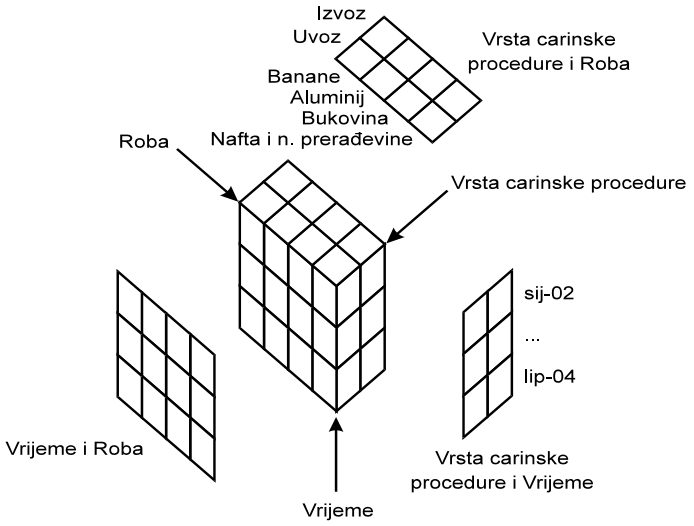
F(t-1)(3) - trostruko izglađivanje u prethodnom razdoblju.

3. Integracija modela podataka i metoda prognoziranja uvoza i izvoza

3.1. Multidimenzijski model podataka uvoza i izvoza

Multidimenzijski model podataka uvoza i izvoza najjednostavnije će se prikazati dimenzijama podatkovne kocke (Slika 3.1.).

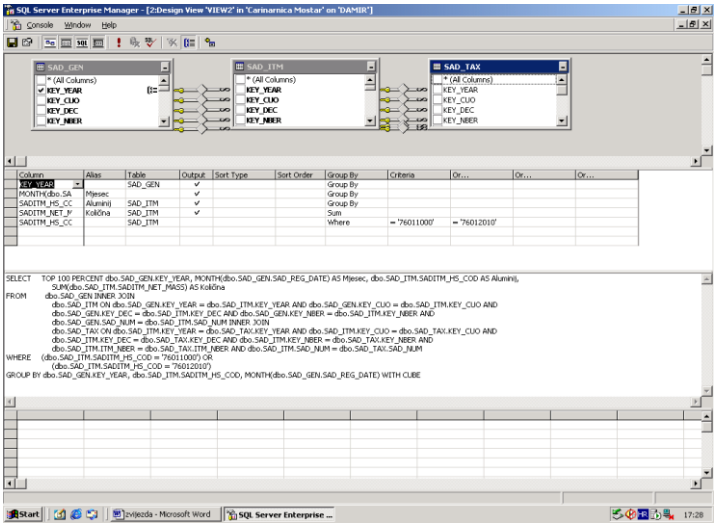
Slika 3.1. Dimenzije podatkovne kocke u multidimenzijskom modelu podataka uvoza/izvoza



3.2. Dizajn relacijskog OLAP-A

Kako bi se dobili potrebni podaci, odnosno kako bi se kreirale tablice dimenzija i vrijednosti uvoza i izvoza, korist će se SQL Server. U primjeru se koristi baza podataka Uprave za neizravno oporezivanje (podaci bivše Carinarnice Mostar) u ORACLE-u. Podaci su očišćeni i učitane tri glavne tablice i postavljene relacije između njih, te je formirano skladište podataka podesno za analizu. (Slika 3.2. i 3.3.).

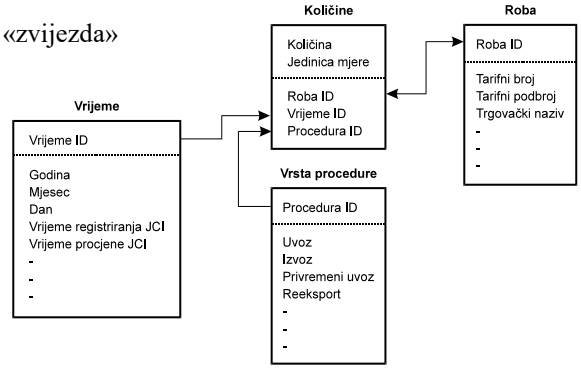
Slika 3.2. Postavljanje SQL upita nad skladištem podataka u SQL Server Enterprise Manageru korištenjem operatora podatkovne kocke (data cube)



3.3. Tablice dimenzija uvoza i izvoza

Jedan od mogućih načina formiranja tablica dimenzija iz velikog broja podataka koje sadrže izvorne baze podataka bivše Carinarnice Mostar, dan je na Slici 3.3.

Slika 3.3. Shema «zvijezda»

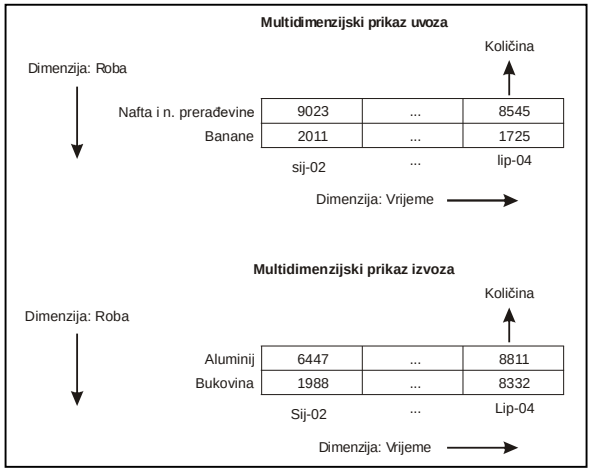


Izvorna baza podatka je ogromna i ima veliki broj tablica, stoga je ista za specifične potrebe prognoze maksimalno pojednostavljena, te je napravljeno skladište podataka koje zadovoljava sve potrebe ovoga primjera.

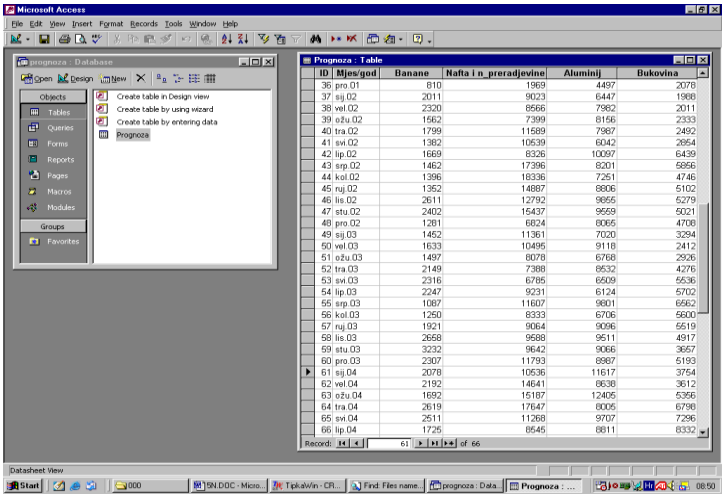
3.4. Tablice vrijednosti uvoza i izvoza

Tablice dimenzija uvoza i izvoza su: Vrijeme, Roba i Vrsta procedure. Tablica vrijednosti (fact table) je: Količine. U toj tablici jedna vrijednost mora biti numerička i ona se naziva mjera (vrijednosti količina u tonama (T)).

Slika 3.4. Tablice vrijednosti uvoza i izvoza



Slika 3.5. Podaci o količinama uvezene i izvezene robe po godinama i mjesecima učitani u MS Access



3.5. Primjer prognoze uvoza/izvoza

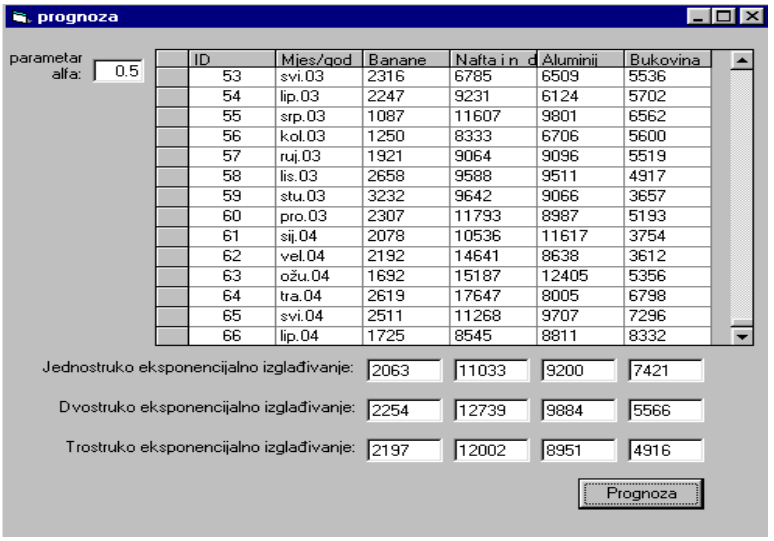
Prikazat ćemo primjer prognoze korištenjem metode jednostrukog, dvostrukog i trostrukog eksponencijalnog izglađivanja. Prethodno opisanim postupcima, formirano je skladište podataka u MS Accessu. Podaci za ovaj primjer uzeti su u razdoblju od siječnja 1999. do lipnja 2004. Program koji izvršava funkciju prognoze, uzimanje podataka iz skladišta te prikazuje rezultat prognoze, napravljen je u MS Visual Basicu.

Prognoza će uvoza biti izvršena za banane i naftu i naftne prerađevine, a izvoza za aluminij i bukovinu. Koeficijent α je, kako je prethodno objašnjeno, opcionalan. Dio programskog koda napisanog u MS Visual Basicu je sljedeći:

```
Dim strPodaci As String
Dim pAlfa As Double
Dim Ystvr As Double
Dim Fprprog As Double
Dim Fprprog1 As Double
Dim F2prprog01 As Double
Dim F2prprog As Double
Dim F2prprog1 As Double
Dim F3prprog01 As Double
Dim F3prprog As Double
Dim F3prprog1 As Double
Private Sub cmdPrognoza_Click()
pAlfa = alfa
With rsPodaci.Recordset
For i = 2 To 5
  .MoveFirst
  Fprprog = 0
  F2prprog = 0
  F2prprog1 = 0
  F3prprog = 0
  F3prprog1 = 0
  pomrecno = 1
  Do While Not .EOF
    Ystvr = .Fields(i).Value
    Fprprog1 = Fprprog + pAlfa * (Ystvr - Fprprog)
    If pomrecno > 1 Then
    F2prprog1 = pAlfa * Fprprog + (1 - pAlfa) * F2prprog01
    End If
    F2prprog01 = F2prprog
    If pomrecno > 1 Then
    F3prprog1 = pAlfa * F2prprog + (1 - pAlfa) * F3prprog01
    Else
      pomrecno = 2
    End If
    F2prprog = F2prprog1
    F3prprog01 = F3prprog
    F3prprog = F3prprog1
    Fprprog = Fprprog1
    .MoveNext
  Loop
  Select Case i
    Case 2
      txtBanane = Int(Fprprog1)
      txtBanane2 = Int(F2prprog1)
      txtBanane3 = Int(F3prprog1)
    Case 3
      txtNafta = Int(Fprprog1)
      txtNafta2 = Int(F2prprog1)
      txtNafta3 = Int(F3prprog1)
    Case 4
      txtAluminij = Int(Fprprog1)
      txtAluminij2 = Int(F2prprog1)
      txtAluminij3 = Int(F3prprog1)
    Case 5
      txtBukovina = Int(Fprprog1)
      txtBukovina2 = Int(F2prprog1)
      txtBukovina3 = Int(F3prprog1)
  End Select
Next
End With
End Sub
Private Sub Form_Load()
strPodaci = "Provider=Microsoft.Jet.OLEDB.4.0;
Data Source=C:\My   Documents\prognoza.mdb;Persist
Security Info=False"
rsPodaci.ConnectionString = strPodaci
rsPodaci.RecordSource = "prognoza"
Set dgPodaci.DataSource = rsPodaci
dgPodaci.Columns.Item(0).Alignment = dbgCenter
End Sub
```

Rezultati prognoze su dani na Slici 3.6.:

Slika 3.6. Rezultat prognoze uvoza/izvoza za srpanj 2004.



U polju prognoza dobiveni su rezultati prognoze za idući mjesec (srpanj 2004.), na temelju koje se u idućem koraku dobije prognoza za kolovoz 2004. itd.

Središte OLAP koncepta je podatkovna kocka, multidimenzijski pregled podataka. OLAP se koristi za agregiranje, pregledavanje, analiziranje i sintetiziranje podatka sukladno višestrukim dimenzijama. Multidimenzijska tehnika baza podataka (multidimenzijski OLAP) primjenjuje se u aplikacijama za potporu odlučivanju. Podaci su pohranjeni u multidimenzijskim strukturama (MOLAP), što je prirodniji način za izražavanje multidimenzionalnosti podataka poduzeća i pogodnije je za analize. Naglašena je i bliska veza između modeliranja podataka i metoda za donošenje odluka. Specijalisti baza podataka i modela (osobe odgovorne za strukturiranje i implementaciju multidimenzijskih baza podataka i modela korištenih u procesu odlučivanja) moraju osigurati adekvatnost strukture u modelu odlučivanja strukturi podataka. Bez prednosti i spajanja modeliranja podataka i znanosti o upravljanju (menadžmentu) utemeljene na modelima, nije moguće poboljšati donošenje odluka i uspješnu uporabu potencijala informacijske tehnologije u ostvarivanju strateških prednosti.

4. ZAKLJUČAK

Kao što je od ranije poznato, učinkovito izvođenje upita nad skladištem podataka nije moguće uporabom select SQL naredbe te se za provođenje multidimenzijske analize uvodi novi operator, operator podatkovne kocke. Međutim, i on predstavlja tradicionalni alat za upite i izvješća, koji omogućuje vjeran opis podataka u skladištu podataka, točan pregled sadržaja pohranjenog u bazi podataka. OLAP ide dalje jer za pronalaženje odgovora koristi i dodatno pitanje: Zašto su određene hipoteze istinite? Korisnik formira hipotezu o odnosima unutar baze podataka ili skladišta podataka i provjerava je nizom upita nad podacima. OLAP analitičar generira niz hipotetičkih pravilnosti i relacija, a upite prema bazi podataka koristi za dokazivanje ili odbacivanje pravilnosti.

Bit OLAP poslužitelj tehnologije je brza i fleksibilna agregacija podataka i analiza. Dok SQL baze podataka nastavljaju dominirati on-line transakcijskom obradom (gdje je nužna slog-po-slog obrada), OLAP poslužitelji imaju superiornu tehnologiju za aplikacije poslovne inteligencije. Učinkovita i fleksibilna analiza podataka zahtijeva sposobnost agregacije podataka na više strojeva i pregled trendova tijekom vremena. OLAP poslužitelji mogu isporučiti podatke korisniku brzo i omogućiti im izvođenje analize neophodne za donošenje najbolje poslovne odluke.

Logička progresija informacijskih sustava vodi od transakcijskih informacijskih sustava (TIS) preko menadžerskih informacijskih sustava (MIS), sustava potpore odlučivanju (DSS), izvršnih informacijskih sustava (EIS), do inteligentnih sustava potpore odlučivanju (IDSS). Istodobno, svjedoci smo intenzivnog približavanja informacijskih sustava i poslovnih obrada. Njihove uobičajene značajke su skladištenje, analiza i sintetiziranje odgovarajućih podataka.

U iznimno dinamičnom i konkurentnom poslovnom okruženju menadžeri su prisiljeni donositi brze i učinkovite odluke kako bi sačuvali strateške prednosti svoga poduzeća između konkurentnih poduzeća. No, to nije laka zadaća, poglavito u situaciji kada između mnoštva dostupnih podataka, iz gotovo neograničenih izvora, moraju odvojiti bitne od nebitnih kako bi otkrili prikrivene trendove i pravila. Težina hvatanja ukoštac s masom različitih podataka stalni je križ na leđima suvremenih menadžera. Stoga, u pokušaju rješavanja tih problema oni se moraju koristiti računalima. Naime, dok razvitak tehnologije (hardver, softver, komunikacije, mreže, Internet itd.) stvara eksplozivnu masu podataka s jedne strane, s druge pak strane, to nudi rješenja problema ukoliko se tehnologije opisane u ovome radu kvalitetno koriste.

Ako se broj promjenjivih koje se analiziraju povećava na stotine ili tisuće, onda je gotovo nemoguće pronaći hipotezu o odnosima između polja unutar relacijske tablice. Alati za traganje kroz podatke (data mining) rabe podatke u bazi podataka za otkrivanje pravilnosti i veza, zakonitosti, umjesto da provjeravaju istinitost hipoteza. Tako analitičar može otkriti i nove čimbenike o kojima ranije nije ni razmišljao. Taj čimbenik čini OLAP i data mining alate komplementarnim.

Značajan problem pri prognozi uvoza i izvoza nisu nedostaci informatičkih alata, muldimenzijske analize ni metoda prognoziranja, nego netočnost podataka, krijumčarenje, carinske prijevare, korupcija, politika, a prije svega nejedinstven ekonomski prostor. Mnogi od tih problema riješeni su ujedinjavanjem carinskih uprava Federacije BiH, Republike Srpske i Distrikta Brčko pod okriljem Uprave za neizravno oporezivanje. Sljedeći korak je uspostava jedinstvenog ekonomskog prostora i pravilnog funkcioniranja tržišta Bosne i Hercegovine, što je preduvjet za implementiranje bilo kakve razvojne strategije i politike, kao i za članstvo u Svjetskoj trgovinskoj organizaciji (WTO) i Europskoj uniji.

Tek tada će biti stvoreni preduvjeti za kvalitetno prognoziranje uvoza i izvoza te uspostavu i razvitak sustava poslovne inteligencije koja u procesima prikupljanja, upravljanja i analizi podataka bitno doprinosi opstanku i učinkovitom funkcioniranju poduzeća ujedinjujući interne podatke i podatke iz okoline sa znanjima u poduzeću.

Primjenom sustava za potporu odlučivanju može se bitno povećati kvaliteta odlučivanja, skratiti vrijeme odlučivanja, povećati produktivnost. Oni mogu biti moćan alat na raspolaganju menadžerima. Zato je uporaba računalnih sustava za potporu odlučivanju u većini organizacija postala nužnost zbog ograničenih ljudskih sposobnosti u smislu brzog sagledavanja i kvalitetnog rješavanja kompleksnih problema.

SUMMARY

One of the management problems is the lack of quality data, which does not mean that they do not exist. On the contrary, we are usually swamped with unnecessary data. The problem is how to separate the one essential for decision making from such a mass of data. Data are a part of a company's assets and, along with capital and human resources, it is an important part of an overall competitiveness. Various software tools for decision making support system building enable analyses, particularly those for forecasting leading economic indicators.

This paper presents the application of modern methods for transforming data into business intelligence. The business intelligence is a process lacking in a large number of organizations which seek to obtain information from available data. Such primary data on transactions are a clear indicator of the situation, a clear indication of what is happening in the organization. They do not give a clear answer as to why something happens, do not diagnose processes and changes, interpret results, classify information, determine clusters, modelling dependencies among data, reveal no changes or deviations in relation to the set goals, do not determine a correlation between the data, generate association rules or a correlation between records in a database. We cannot provide direct answers to the above questions with transaction data.

Data warehousing, online analytical processing and knowledge discovery in databases and warehouses are the most significant and important new technology in the field of commercial data processing. An integration of IT tools (OLAP, data mining) and appropriate quantitative and qualitative decision models results in new types of information systems for decision support (from executive information systems, strategic information systems to intelligent decision support systems).

This paper researches how data cube models and decision-making models "cooperate" in the case of import/export forecasting.

Keywords: *Data cube, OLAP, business intelligence, DSS, import/export forecasting.*

LITERATURA:

1. Datta, A.,Thomas, H. , 1999., The cube data model: a conceptual model and algebra for on line analytical processing in data warehouses, decision support systems, Vol. 27, North Holand,
2. Dhar, Vasant, Stein, Roger, 1997., Seven Methods for Transforming Corporate Data into Bussiness Intelligence, Prentice-Hall, New Jersey,
3. Ho, C. T. et al., 1997., Range queries in OLAP data cubes in Proceeding Management of Data, Tuscon, Arizona,
4. Jiawei H., Micheline K., 2006., Data mining: Concepts and Techniques (second edition), University of Illinois at Urbana-Champaign, Elseiver, New York,
5. Keen, P.G.W. and Morton M.S, 1978., Decision Support Systems, An organizational Perspective, Addison-Wesley, Reading, Massachusetts,
6. Makridakis, S., Wheelwright, S. C., 1989., Forecasting methods for management, fifth edition, John Willey, Toronto, Canada,
7. Sauter, V. L., 1997., Decision Support Systems: An Applied Managerial Approach, John Willey&Sons INC., New York,
8. Šilj, M., 1998., Uvod u modernu poslovnu statistiku, Tonimir, Varaždinske Toplice,
9. Vujinović, R., 1995., SQL i relacijski model podataka, Znak, Zagreb.