

Ksenija Dumičić*
Silvana Knežević**

UDK 338.27 (497.5)
JEL Classification D21, C53
Izvorni znanstveni rad

ANKETNO ISTRAŽIVANJE PRAKSE PREDVIĐANJA PROMJENA U VLASTITOME POSLOVANJU I U POSLOVNOME OKRUŽENJU HRVATSKIH PODUZEĆA

U suvremenom se poslovanju većina poduzeća u kratkom razdoblju susreće s velikim brojem promjena, pa za menadžment postaje sve važnije točno predviđati promjene u poslovnome okruženju i u vlastitome poslovanju. Predviđanje se definira kao ispitivanje djelovanja vanjskih i unutarnjih čimbenika na buduće poslovanje poduzeća korištenjem kvalitativnih metoda zasnovanih na subjektivnoj procjeni. Ciljevi su rada: (1) prikazati metode predviđanja promjena u poslovnome okruženju i u vlastitome poslovanju i (2) ispitati koliko se i kako koriste metode predviđanja u hrvatskim srednjim i velikim poduzećima. Obavljeno je originalno anketno istraživanje na uzorku poduzeća koje je pokazalo da hrvatska velika i srednja poduzeća u većini slučajeva samostalno izrađuju predviđanja promjena, pri čemu se najčešće koriste vanjskim izvorima informacija, metodama istraživanja tržišta i osobnom procjenom. Rezultati istraživanja pokazuju da među poduzećima postoji razlika prema porijeklu vlasništva. Tako privatna poduzeća poslovnu aktivnost i financijski rezultat predviđaju češće od poduzeća sa državnim i mješovitim vlasništvom.

Ključne riječi: predviđanje, anketno istraživanje, kvalitativne metode, prosudbene metode predviđanja.

* Ksenija Dumičić, redoviti profesor, Katedra za statistiku, Ekonomski fakultet Sveučilišta u Zagrebu, kdumicic@efzg.hr

** Silvana Knežević, mr. sc., Hrvatska agencija za nadzor financijskih usluga (HANFA), silvana.knezevic@hanfa.hr

Prvobitna verzija članka primljena u uredništvo: 2. 2. 2007., a definitivna 5. 4. 2007.

1. Uvod

Promjene s kojima se poduzeća suočavaju u suvremenom poslovanju sve se brže odvijaju. Za dio poduzeća takva brzina promjena postaje sve veća prijetnja, i to zato što se sve češće nalaze u situacijama na koje nisu spremna. Sa druge pak strane, za dio poduzeća upravo ta brzina promjena postaje šansa, jer prilagodbom bržom od konkurencije postaju sve uspješnija. No, brza i odgovarajuća prilagodba promjenama moguća je samo ako menadžment poduzeća unaprijed predviđa promjenu, ali i svoju reakciju na novonastalu situaciju, pa je zato predviđanje neodvojivi dio dugoročnog i strateškog planiranja.

Predviđanje se može definirati kao prosuđivanje budućnosti, odnosno kao ispitivanje djelovanja vanjskih i unutarnjih činitelja na buduće poslovanje poduzeća. Svrha predviđanja u poduzeću jest utvrditi mogući razvitak gospodarskih pojava značajnih za sadašnje poslovne odluke poduzeća (Buble, 1997.). U ovome istraživanju pojmom «predviđanje» koristi se za označivanje prognoziiranja koje je ponajprije zasnovano na subjektivnim, odnosno na kvalitativnim metodama (DeLurgio, 1998.).

Predviđanje može biti usmjereno na promjene u poslovnom okruženju ili na vlastito poslovanje. Promjene u okruženju posljedica su kompleksnih utjecaja - istovremeno socioloških, ekonomskih, tehnoloških i političkih promjena, ali i promjena u okolišu uvjetovanih prirodnim procesima ili ljudskom aktivnošću. Predviđanje tih promjena važno je da bi poduzeće moglo brže reagirati na one događaje u okruženju koji utječu na njegovo poslovanje. Promjene u poslovanju rezultat su promjena u okruženju ili vlastitih aktivnosti poduzeća, a manifestiraju se kao promjena udjela na tržištu, vrijednosti prodaje, troškova i u konačnici financijskih rezultata poslovanja.

Predmet je ovoga rada praksa predviđanja promjena u uvjetima neizvjesne budućnosti i nepredvidivih socijalnih i ekonomskih neizvjesnosti i trendova kretanja pojava u vlastitom poslovanju i u okruženju hrvatskih velikih i srednjih poduzeća. Na osnovi toga definiran je i glavni cilj istraživanja, a to je donošenje zaključaka o primjeni, ulozi, značaju i osnovnim karakteristikama prakse predviđanja u anketiranim hrvatskim poduzećima. Isto je tako cilj rada i prikazati kojim se metodama predviđanja promjena najčešće koriste u hrvatskim poduzećima i koji su predmeti predviđanja (različiti aspekti promjena u okruženju i u vlastitom poslovanju). Stoga je i istraživanje obavljeno tako da se metodom ankete na odabranom uzorku poduzeća mogu ispitati slijedeće hipoteze:

- H1: Predviđanje promjena u vlastitome poslovanju i u poslovnome okruženju dio je prakse hrvatskih srednjih i velikih poduzeća.
- H2: Hrvatska srednja i velika poduzeća najčešće se koriste metodama istraživanja tržišta i osobnom procjenom kao osnovom predviđanja promjena u poslovanju i u poslovnome okruženju.

- H3: Postoji veza između oblika vlasništva nad poduzećem i predmeta predviđanja promjena u poslovanju.

Istražena literatura nije ukazala na slična istraživanja u Hrvatskoj, osim, kako je to dano u radu Ćurlin (2006.) u kojem se govori o primjeni metoda predviđanja u strateškom planiranju hrvatskih poduzeća. U skladu s definiranim hipotezama, ovaj je rad zasnovan na originalnom istraživanju i daje odgovore na slijedeća pitanja: (1) Predviđaju li hrvatska srednja i velika poduzeća budućnost?; (2) Kojim se metodama pritom koriste i kako organiziraju postupke predviđanja u poduzeću?; (3) Utječe li oblik vlasništva utjecaja nad predmetom predviđanja promjene u poslovanju?

2. Predviđanje promjena u poslovnome okruženju i u vlastitoj okolini

Postupci prosuđivanja o budućnost u literaturi se opisuju dvama terminima: «prognoziranje» i «predviđanje»¹. Potrebno je istaknuti da korištenje termina ovisi o osnovnome pozivu (vokaciji) autora. Statističari-prognostičari koriste se nazivom «prognoza», jer se statistička znanost naslanja na kvantitativne pokazatelje postojećih događanja i pojava. Može se uočiti da se statističari-prognostičari bave budućim kretanjima pojava koje već postoje, koje su nastale i o kojima postoje sudovi, mišljenja i slično.

Za razliku od riječi «prognoza», terminom «predviđanje» više se koristi u literaturi strategijskog menadžmenta (Godet, 1987.). Promjene u okruženju i u vlastitome poslovanju nastoje se predvidjeti kvantitativnim, ali i kvalitativnim metodama predviđanja (Porter et al., 1991.). No osnovni je razlog razlike zapravo taj što se u okviru strateškog menadžmenta, a osobito planiranja, aktivnosti predviđanja promjena ne ograničuju samo na pojave koje postoje i koje u budućnosti mogu poprimiti različite vrijednosti ili tijekom kretanja, nego je potrebno predvidjeti i neke nove pojave, događaje i slično koji bi se mogli odraziti na okruženje, a time i na organizaciju i njezinu viziju i strategiju poslovanja (Ringland, 1998.). Zbog toga se u radu koristi terminom „predviđanje“, jer on obuhvaća različite kvalitativne metode prognoziranja i predviđanja zasnovane na subjektivnim inputima i outputima.

Za razliku od kvantitativnih metoda zasnovanih isključivo na primarnim i sekundarnim numeričkim podacima i kod kojih subjektivnost postoji jedino u

¹ Engl. *forecasting* = prognoziranje; engl. *prediction method* = metoda predviđanja, a predviđanje se može nazvati i engl. *foresighting*.

odabiru metode prognostičara, metode predviđanja uglavnom se zasnivaju na subjektivnoj procjeni kao osnovi za prosuđivanje. Karakteristično je korištenje ocjene budućih stanja koju daju stručne osobe, a koja proizlazi iz poznavanja predmetnog područja djelatnosti. Takve se ocjene sastoje od jednostavnih sudova do sudova apodiktičke prirode, ali svi ti sudovi ne proizlaze bezuvjetno iz nekog statističkoga ili matematičkoga modela kao apodiktički vrijednosni sud.

Zbog subjektivnih i kvalitativnih procjena za metode predviđanja koristi se i nazivom prosudbene (engl. *judgmental*) metode. Isto se tako, zbog učestale primjene u dugoročnom prognoziranju, nazivaju i metodama dugoročnog prognoziranja (engl. *long-term forecasting*), a zbog primjene u dugoročnim prognozama novih tehnologija DeLurgio (1998.) ih naziva i tehnološkim metodama prognoziranja (engl. *technological forecasting methods*).

Metodama predviđanja najčešće se koriste u ovim situacijama: (1) za izradu srednjoročnih i dugoročnih prosudbi u strateškom planiranju, (2) za razvijanje novih proizvoda i usluga, (3) za izradu dugoročnih planova i (4) kada ne postoji dovoljan broj podataka o predmetnim uzorcima ili odnosima iz prošlosti (Schwartz, 1996.).

Neupitna je njihova velika pomoć u poslovnom upravljanju, unatoč teškoćama u mjerenju njihove učinkovitosti i njihove vrijednosti kao metoda prognoziranja. Makridakis, Wheelwright i Hyndman (1998.) podrazumijevaju učinkovito korištenje kvalitativnih metoda usporedno s kvantitativnim metodama prognoziranja u područjima razvijanja proizvoda, kapitalnih izdataka, u formulaciji strategije i izbora ciljeva, u spajanjima. Njihova primjena nije ograničena samo na velika poduzeća, pa se primjenjuje i u malim i srednjim poduzećima.

3. Metode predviđanja promjena u poslovnome okruženju i u poslovanju

U ovome dijelu rada daje se pregled osnovnih kvalitativnih metoda predviđanja (Moutinho et al., 1998.), a te su:

- (1) subjektivne metode predviđanja,
- (2) istraživačke ili eksplorativne metode,
- (3) normativne prognostičke metode i
- (4) S-krivulje rasta.

3.1. *Subjektivne metode predviđanja*

Subjektivnim metodama koristi se u svakodnevnom predviđanju kada se procjenjuju učinci promocije, promjene cijena, kompeticije, a pritom se najčešće koriste: (1) panel-konsenzusom, (2) kompozicijom sila prodaje i (3) istraživanjem tržišta.

Panel- konsenzus metoda (engl. *jury of executive opinion*) prognostička je metoda koja se primjenjuje u tijeku sastanka menadžmenta poduzeća. Ta je metoda osnovana na teoriji da iskustva i mišljenja nekoliko stručnjaka daju bolje prognostičke rezultate od procjene jednoga stručnjaka.

Metode kompozicije sila prodaje (engl. *sales force composite methods*) zasnivaju se na iskustvu prodajnog osoblja kao izvoru informacija za projekcije koje se većinom odnose na trendove u potražnji i u ponašanju kupaca. Uobičajeno je da se metode kompozicija sila prodaje primjenjuju za određenu regiju ili područje nakon čega se skupina regionalnih procjena agregira, pa se procjene donose na razini poduzeća. Takva se projekcija može primijeniti i za uspoređivanje s prognozama učinjenim formalnim metodama, npr. analizom vremenskih serija i sl.

Kod *istraživanja tržišta* aktualni i potencijalni kupci anketiraju se o potražnji, poželjnim karakteristikama proizvoda i slično. Uzorak za donošenje prognostičkih procjena kod tih je metoda mnogo veći nego kod ostalih navedenih subjektivnih metoda prognoziranja. Iako se ovdje radi o subjektivnoj metodi, dakle, o metodi zasnovanoj na subjektivnoj procjeni ispitanika, sama provedba istraživanja tržišta i anketnih istraživanja zasniva se na formalnim, objektivnim i statističkim pravilima i metodama.

3.2. *Istraživačke ili eksplorativne metode predviđanja*

Istraživačke ili eksplorativne metode predviđanja (engl. *exploratory forecasting methods*) označuju metode kojima se prosuđuju alternativne mogućnosti u budućnosti. Ta se definicija može proširiti, ne samo na alternativne mogućnosti u budućnosti, nego i na različite druge moguće budućnosti, jer će se poduzeća često naći pred odabirom i više od dva smjera odvijanja zamišljene budućnosti. Osim strateškog planiranja, te metode imaju široku primjenu i u donošenju odluka i u analizi posljedica odluka.

U te se metode ubrajaju: metoda scenarija, Delfi metoda, proces nominalnih grupa, metoda studije slučaja, analitički uvid u hijerarhijski proces, analiza međutjecaja i metoda analogije.

Analiza scenarija metoda je predviđanja kojom se pokušava vizualizirati određeni broj mogućih budućnosti i razmotriti njihove implikacije. Scenariji se djelomično zasnivaju na izvornim podacima sa subjektivnim interpretacijama i specifičnim pretpostavkama o kritičnim pristupima stvarnosti prema budućnosti (Makridakis, Wheelwright i Hyndman, 1998).

Delfi metoda jedna je od najpoznatijih kvalitativnih metoda prognoziranja ili metoda predviđanja. Primjenjuje se za prognozu vjerojatnosti i vremena odvijanja budućih događaja. Da bi dala prognozu, skupina stručnjaka identificira i definira predmetni događaj, vjerojatnost njegovog odvijanja i moguće vrijeme budućega događaja. Delfi metoda važna je zbog nepristranosti sudionika jer se mišljenja i pretpostavke stručnjaka koji prognoziraju zasnivaju na prikupljanju podataka anketiranjem, tj. ispunjavanjem upitnika. Upitnik stručnjaci ispunjavanju neovisno jedan o drugome, a to ovoj metodi daje karakter nepristranosti u prosuđivanju (Linstone i Turoff, 2002.).

Proces nominalnih grupa (engl. *nominal group process*) metoda slična je Delfi metodi zato što se koristi panel-stručnjacima koji neovisno jedan o drugom daju svoje mišljenje o vjerojatnosti pojave i o razvijanju novih tehnologija. Kod ove metode, za razliku od Delfi metode, nakon definiranja stavova stručnjaci se okupljaju i razvija se otvorena diskusija radi postizanja konsenzusa o bitnom.

Metoda studije slučaja (engl. *case-study method*) sastoji se od proučavanja prošlih i sadašnjih pojedinih slučajeva ili procesa. Primjerice, ako se analiziraju primjene tehnologija u praksi, uz simulaciju sličnih uvjeta, izvode se zaključci koji su primjenjivi na prognozu moguće nove tehnologije.

Analitički hijerarhijski proces (engl. *analytic hierarchy process*) metoda je kojom se utvrđuju kriteriji za identifikaciju odnosa između varijabli pri čemu se koristi usporedbom parova. Nekoliko stručnjaka naprave usporedbu parova, pa se na osnovi te usporedbe identificira njihov matematički odnos, odnosno apodiktički vrijednosni sud.

Analizom međuučecaja (engl. *cross-impact analysis*) procjenjuje se efekt nekoliko budućih događaja na vjerojatnost drugoga događaja (kao što je, primjerice, razvijanje nove tehnologije), odnosno određuje se utjecaj jedne na jednu ili na više drugih prognoza, a često se primjenjuje uz Delfi metodu i metodu analize scenarija.

Makridakis, Wheelwright i Hyndman (1998.) navode *dugoročne megatrendove* koji se po definiciji s vremenom rijetko mijenjaju upravo zbog svoga dugoga trajanja. Takvi se dugoročni trendovi, navodi autor, mogu ekstrapolirati s velikom dozom sigurnosti u prosudbu, osim u slučajevima promjene sustava u osnovnom smislu. Ipak, i unutar dugoročnih mega trendova postoje devijacije u obliku ciklusa koji mogu trajati, primjerice, i desetljećima, pa predstavljaju izazov i za prognozere i za strateške planere. Cikluse nije moguće predvidjeti, kako izno-

si Makridakis (1996.), u kvantitativnom obliku zato što njihovo trajanje i dubina nisu konstante već ovise o mnogo varijabli.

Metoda analogije veoma je popularna metoda u kratkoročnom, srednjoročnom i osobito u dugoročnom prognoziranju za proizvode i tehnologije sličnih karakteristika. Analogijom se, prema Makridakisu (1996), u kratkome roku koristi za prognoziranje utjecaja osobitih događaja ili konkurentskih aktivnosti zasnovanih na prošlim primjerima. Autor navodi i primjenu analogije za procjenu u srednjem roku za, npr., dužinu trajanja recesije stavljanjem u odnos tekuće recesije s trajanjem kumulativa uzroka svih recesija nakon Drugoga svjetskoga rata. U dugome roku analogijom se koristi za predviđanje neke pojave na osnovi usporedbe s ponašanjem neke slične pojave.

3.3. Normativne prognostičke metode

Normativne prognostičke metode zasnovane su na premisi o budućnosti na koju se može utjecati. Poslovne organizacije dostižu željene ciljeve definirajući željenu budućnost i poduzimajući aktivnosti potrebne za postizanje te budućnosti. U normativne prognostičke metode uvrštavaju se: (1) metoda stabla značajnosti i (2) dinamika sustava.

Metoda stabla značajnosti (engl. *relevance trees*) koristi se metodologijom i konceptom sličnim teoriji i stablu odlučivanja za mjerenje učinkovitosti ponašanja poduzeća prema budućim ciljevima i za identifikaciju potrebnog za postizanje željenih ciljeva. Tom se metodom često koristi za evaluaciju ostvarenja nacionalnih ciljeva kojima je svrha postići ciljeve na vojnom i na medicinskom području. Smisao i značenje metode sastoje se u tome da se ciljevi primjene novih tehnologija rastave na niže ciljeve s primjenom u obliku stabla.

Dinamika sustava (engl. *system dynamics*) metoda je koju je godine 1957. zasnovao J. Forrester. Radi se o proučavanje jednostavnih i složenih sustava i odnosa u njima uz pomoć diferencijalnih jednadžbi (Sterman, 1994.).

3.4. S-krivulje rasta

Metoda predviđanja S-krivuljama rasta obuhvaća različite verzije Gompertzovih i logističkih krivulja koje se nazivaju još i krivuljama rasta, zasićenja ili supstitucije. Pod metodama S-krivulja rasta podrazumijevamo slijedeće metode-krivulje: (1) krivulje životnoga ciklusa; (2) krivulje supstitucije; (3) Gompertzove krivulje; (4) logističke krivulje.

Osnovni je smisao krivulja rasta da nakon početnoga sporoga rasta barijere za prihvaćanje i prilagodbu opadaju, pa nastupa faza ubrzanoga rasta. Ubrzani rast ne može se održavati zbog različitih zakonitosti i odnosa koji definiraju gornju razinu mogućnosti određene tehnologije. Zrela tehnologija ima usporeni rast, jer je do tada unaprijeđen postojeći tehnološki proces, čime rastu i mogućnosti za nove tehnologije. Inventivnost i inovativnost dovode do zamjene stare tehnologije novom i do pokretanja novoga životnoga ciklusa.

4. Predmet predviđanja promjena u poslovnome okruženju i u vlastitome poslovanju

Predviđanje promjena može se podijeliti na dvije osnovne skupine: (1) predviđanje promjena tržišnih okolnosti u poslovnome okruženju - ekonomskom, političkom itd. i socijalnih okolnosti i (2) predviđanje vlastitoga poslovanja.

U odnosu na aspekte vanjskoga i općega okruženja najviše su razvijena *predviđanja varijabli tržišnog okruženja*. Varijable tržišnog okruženja obično su kvantitativnog karaktera, pa se zato ovdje uglavnom primjenjuju kvantitativne metode i modeli prognoza. Prognoziraju se obično stope rasta dohotka po stanovniku, stope inflacije, kamatne stope, indeksi troškova života i slično. Ekonometrijski modeli bili su osobito popularni u sedamdesetim godinama 20. stoljeća u vrijeme kada je cvalo „strateško planiranje“. Rastom cijena nafte na međunarodnim tržištima, inflacijom i općim poremećajem na svjetskom gospodarskom planu ekonometrijski su modeli doživjeli neuspjeh zato što su bili smišljeni za prognoze i simulacije pojava u stabilnome okruženju. Stoga se za prognoze i predviđanja pojava u gospodarskome dijelu vanjskoga okruženja češće koristi metodama na osnovi vremenskih serija u kombinaciji s kvalitativnim metodama prognoziranja.

U dijelu promjena *socijalnog okruženja* situacija je bitno drugačija zato što se društvene promjene u odnosu na gospodarsko okruženje rijetko mogu kvantificirati. To se ne odnosi na demografske pojave tipa broja stanovnika, promjene sustava i ostalih brojčanih pokazatelja o stanovništvu (kućanstva, dob, dohodak, članovi obitelji). No, socijalna kretanja kao što su sustavi vrijednosti, normi i predrasuda nije moguće brojčano prikazati, a još je teže prikazati promjene u sustavu socijalnih i gospodarskih odnosa.

Tako se za potrebe prognoza pojava i promjena društvenoga okruženja primjenjuju kvalitativne metode predviđanja, pri čemu se ističu analiza scenarija, panel-konsenzus metoda, delfi metoda i slično ili metode zasnovane na subjektivnoj prosudbi, a ne na statistički zasnovanoj metodologiji.

Političko okruženje i sustav socijalnih odnosa sa stalnim promjenama postaju sve značajniji, što pokazuje da pojave političke prirode snažno utječu na gospo-

darska kretanja, a time i na poduzeća i njihove strategije, osobito sada u uvjetima globalizacije ultimativnog poduzetništva. Zbog velikih se ulaganja u inozemstvu političkim prilikama i osobito političkim rizicima pridaje sve više pozornosti. Tako su nastali brojni sofisticirani modeli za predviđanje političkih prilika i rizika, kreatori kojih su multinacionalne kompanije i savjetničke kuće. Najpoznatiji je takav model ADL (*Arthur D. Little*) model koji prati promjene mnogih zemalja (Pearce i Robinson, 2000.). Prema ovome modelu, uz pomoć računala prati se pet osnovnih kriterija: društveni i tehnološki razvitak, raspoloživost prirodnih resursa, stupanj stabilnosti i oblik političkog i ekonomskog uređenja. Kada rast bilo koje sastavnice ode dalje od rasta ostalih navedenih kriterija, nastupa tenzija koju obično prati i nasilje. ADL model pokazao se uspješnim zato što je predvidio neke krize koje su se stvarno dogodile. Zaključak je da je svijet veoma predvidiv, uz uvjet da se realiziraju dublji uvidi u činjenice relevantne za sociologiju međunarodnih odnosa.

Zato su predviđanja *tehnoloških pojava* i promjena u današnjem svijetu iznimno složena, a kritičari prognostičkog pristupa kažu i gotovo nemoguća bez tih činjenica (Albright, 2002.). Brzinu otkrića u području fundamentalnih znanosti i njihovu primjenu u raznim sferama života gotovo je nemoguće predvidjeti. Zato se u poslovnome okruženju koristi kvalitativnim metodama predviđanja kao što su Delfi metoda, analiza scenarija, itd.

Predviđanja vlastitoga poslovanja najčešće su usmjerena na predviđanje prodaje, financijskih rezultata poslovanja, troškova, udjela poduzeća na tržištu itd. kao predviđanje poslovnih aktivnosti. Ti su pokazatelji međusobno povezani na slijedeće načine: što su manji troškovi, konkurentnost je veća, pa je rezultat poslovanja bolji; što je bolja prodaja, to je veći udio poduzeća na tržištu. I baš zato predviđanje vlastitoga poslovanja često se zasniva na prognozi prodaje, na osnovi koje se izvode troškovi, tržišni udio i financijski rezultat poslovanja.

5. Metodologija istraživanja

Za potrebe ovoga anketnoga istraživanja jedinica izbora, kao elementarna jedinica koja se bira u uzorak, definirana je kao poslovna jedinica², odnosno poduzeće. U radu su obuhvaćena velika i srednja poduzeća, a pritom su srednje velika definirana kao ona sa 51 i više zaposlenika, dok velika imaju više od 250

² Poslovna je jedinica (engl. *business unit*) gospodarska jedinica koja ima za cilj proizvoditi dobra i pružati usluge, a predstavlja sva poduzeća, vladine i nevladine sustave, farme i sve organizacije koje obavljaju komercijalne djelatnosti i komercijalne i industrijske djelatnosti, prema Cox et al. (2005.).

zaposlenika. Izvještajne jedinice one su od kojih su dobijeni podaci (kvantitativne – knjigovodstveni odjel poduzeća, kvalitativne – odgovarajuće osobe). U ovome istraživanju definirane su kao službe ili odjeli strateškog planiranja anketiranih poduzeća. Ispitanici su bili menadžeri zaduženi za strateško planiranje.

Konačni skup jedinica kojih se svojstva žele promatrati i ispitati čine ciljnu populaciju, odnosno osnovni skup koji je predmet anketnog istraživanja (Žugaj, Dumičić i Dušak, 2006.). Tako je ciljna populacija za predmetno istraživanje definirana kao skup velikih i srednjih poduzeća/poslovnih subjekata registriranih u Republici Hrvatskoj koji su objavili financijske rezultate poslovanja za godinu 2003.

Za postupak odabira poduzeća u uzorak korištena je baza Financijske agencije, odnosno popis velikih i srednjih poduzeća rangiranih prema visini ukupnoga prihoda ostvarenoga u godini 2003. Korištena su dva stratuma: jedan za srednja i drugi za velika poduzeća. Za odabir jedinica unutar svakoga stratuma korišten je generator slučajnih brojeva. Model stratificiranog uzorka poduzeća zasnovan na „broju zaposlenika“ kao jedinom kriteriju stratifikacije primijenjen je uz (približno) jednaku alokaciju jedinica uzorka po stratumima i on je osigurao kontroliranu zastupljenost dviju veličina firmi. Tako je u ovo istraživanje na uzorku od $n=112$ poduzeća uključeno:

- $n_1=51$ srednjeveliko poduzeće (s 51-250 zaposlenih), uz udio odnosno frakciju izbora³ od $f_1=0,034$, tako da se 46% uzorka odnosi se na srednjevelika poduzeća;
- $n_2=61$ velikih poduzeća (s više od 250 zaposlenih), uz frakciju izbora od $f_2=0,123$, a što ukazuje da se preostalih 54% uzorka odnosi na velika poduzeća.

Prema Žugaj, Dumičić i Dušak (2006., str. 173) pri procjenjivanju propor-

cije osnovnog skupa $p = \frac{\sum_{i=1}^N y_i}{N}$ unutar svakoga od zanimljivih podskupova popu-

lacije, odnosno stratuma ili poststratuma, kada pojedine vrijednosti varijable y_i , za $i=1, 2, \dots, N$ poprimaju vrijednost 1 ako pripadaju određenoj skupini, a vrijednost 0 ako joj ne pripadaju, tj. za:

$$y_i = \begin{cases} 1 & \text{ako jedinica ima određeni oblik} \\ 0 & \text{ako jedinica nema određeni oblik,} \end{cases}$$

³ Frakcija izbora omjer je veličine uzorka i veličine populacije.

korišten je nepristrani procjenitelj $\hat{p} = \frac{\sum_{i=1}^n y_i}{n}$. Kada je uzorak bio dovoljno veliki, a

to je bilo kada su vrijedile slijedeće relacije: $n \cdot p \geq 5$, odnosno $n \cdot (1 - p) \geq 5$, bilo je opravdano distribuciju procjenitelja aproksimirati s Gaussovom krivuljom. Ako

je bilo ispunjeno i slijedeće: $(\hat{p} - 3\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}) > 0$, a $(\hat{p} + 3\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}) < 1$,

usporedi s McClave, Benson i Sincich (2005), tada se intervalna procjena proporcije mogla izračunati na ovaj način:

$$\Pr\left(\hat{p} - z_{\gamma/2} \sigma_{\hat{p}} \leq p \leq \hat{p} + z_{\gamma/2} \sigma_{\hat{p}}\right) = (1 - \gamma),$$

gdje je standardna pogreška procjene proporcije dana slijedećim izrazom:

$$\sigma_{\hat{p}} = \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \sqrt{\frac{N-n}{N-1}}.$$

Uz frakciju odabiranja manju od 5%, tj. kada je $f = \frac{n}{N} < 0.05$, faktor korekcije za konačne populacije $\sqrt{\frac{N-n}{N-1}}$ približno je jednak jedan, pa se zanemaruje. Uz 95%-tnu razinu pouzdanosti, tj. uz $(1 - \gamma) = 0.95$, uzima se da je faktor pouzdanosti $z_{\gamma/2} = z_{0.025} = 1.96$.

Uzorak za anketno istraživanje za potrebe ovoga rada sastoji se od ukupno 112 poduzeća. Od toga 51 poduzeće pripada stratumu srednjevelikih, a 61 poduzeće iz stratuma je velikih poduzeća. Istraživački je upitnik bio sastavljen od ukupno 33 pitanja podijeljenih u četiri osnovne skupine: (1) pitanja vezana uz postojanje funkcije strateškoga planiranja (5 pitanja); (2) pitanja vezana uz primjenu predviđanja promjena u okruženju poduzeća (5 pitanja); (3) pitanja vezana uz vrstu predviđanja (11 pitanja) i (4) pitanja vezana uz osnovne karakteristike poduzeća (12 pitanja).

U prvome dijelu anketnoga upitnika postavljana su pitanja vezana uz postojanje i izradu strateškoga planiranja u anketiranome poduzeću. Drugim skupom pitanja vezanih uz primjenu predviđanja promjena u okruženju poduzeća pokušalo se dobiti odgovore na pitanja vezana uz korištenje i način izrade predviđanja, a i uz razloge njihove neprimjene ili, pak, neizrade predviđanja. Osim toga, u ovome dijelu upitnika pokušalo se saznati razloge neizrađivanja i neprimjene predviđanja. Pitanja vezana uz vrstu predviđanja imala su svrhu saznati koje metode anketirana

poduzeća primjenjuju prilikom izrade predviđanja. Cilj ove skupine pitanja bilo i otkrivanje kojim metodama predviđanja hrvatska poduzeća pokušavaju povećati kvalitetu i učinkovitost svojih predviđanja.

Posljednjim skupom pitanja, odnosno odgovora, dobiva se potpunija slika o vrsti i značajkama istraživanih poduzeća, bilo da primjenjuju i izrađuju predviđanja ili ne. Neka su pitanja bila zatvorenoga tipa s mogućnošću izbora jednoga ili više ponuđenih odgovora, a druga su bila formulirana kao otvorena pitanja s potpunom slobodom odgovora. Na anketni upitnik najčešće su odgovarali rukovoditelji službi plana i analize, kontrolinga ili direktori i zamjenici direktora.

Prikupljanje podataka provedeno je metodom CATI anketiranja (računalno podržano telefonsko intervjuiranje)⁴. Anketiranje je provedeno u svibnju godine 2004. Primljeni su odgovori od ukupno 112 poduzeća i to je ocijenjeno zadovoljavajućim za potrebe ovoga istraživanja. Za analizu anketnih podataka korištene su metode deskriptivne i inferencijalne statistike uz pomoć statističkih paketa SPSS 9.0 i programa Excel i PHStat2.

6. Rezultati istraživanja

6.1. Praksa predviđanja promjena u poslovnom okruženju i u vlastitome poslovanju

Od ukupnoga broja prikupljenih anketnih odgovora za velika i srednja poduzeća njih 95% daje informaciju da se koriste predviđanjima promjena u okruženju i poslovanju, no to nije slučaj kod 5% poduzeća (valja napomenuti da 6% ispitanika od njih 112 nije odgovorilo na ovo pitanje, a pretpostavlja se da je njihova struktura vezano uz anketno pitanje identična sa strukturom koju su dali ispitanici dostavljenim odgovorima, vidjeti Tablicu 1).

⁴ Anketni podaci prikupljeni su uz pomoć agencije za istraživanje tržišta i javnog mnijenja Puls d.o.o.

Tablica 1.

**KORIŠTENJE PREDVIĐANJA PROMJENA U OKRUŽENJU
U ANKETIRANIM PODUZEĆIMA (N=112, CIJELI UZORAK)**

Predviđanje promjena	Broj odgovora	Struktura u %
Koriste se predviđanjima promjena u okruženju i poslovanju	100	89%
Ne koriste se predviđanjima promjena u okruženju i poslovanju	5	5%
Bez odgovora	7	6%
Ukupno	112	100%

Izvor: Originalno anketno istraživanje.

Dakle, od 105 dobijenih odgovora njih 100, tj. njih 95%, odnosi se na poduzeća koja se koriste nekom metodom predviđanja u okruženju. Pri intervalnom procjenjivanju, sukladno s tablicom 2., uz razinu pouzdanosti od 95%, tj. uz $(1 - \gamma) = 0,95$, očekuje se da je postotak hrvatskih velikih i srednjevelikih poduzeća koja se koriste predviđanjem promjena u okruženju u vrijeme istraživanja između 91,1% i 99,3%. Taj je zaključak zasnovan na slijedećem izračunu:

Tablica 2.

**INTERVAL PROCJENE PROPORCIJE HRVATSKIH VELIKIH
I SREDNJEVELIKIH PODUZEĆA KOJA SE KORISTE
PREDVIĐANJEM PROMJENA U OKRUŽENJU**

Veličina uzorka	105
Broj onih koji predviđaju	100
Razina pouzdanosti	95%
Posredni izračuni	
Proporcija uzorka	0,9524
z vrijednost	-1,9600
Standardna pogreška procjene proporcije	0,0208
Širina polovine intervala	0,0407
Interval pouzdanosti	
Donja granica intervala procjene	0,9116
Gornja granica intervala procjene	0,9931

Izvor: Izračun dobijen softverom PHStat2.

Dalje, proveden je jednosmjerni z test o pretpostavljenoj proporciji populacije uz pretpostavku da je udio poduzeća koja se koriste predviđanjem veći od 80%, kako slijedi u tablici 3:

Tablica 3.

TEST HIPOTEZE O PROPORCIJI HRVATSKIH VELIKIH
 I SREDNJEVELIKIH PODUZEĆA KOJA SE KORISTE
 PREDVIĐANJEM

Z test hipoteze o proporciji	
Nulta hipoteza	$p=$ 0,9
Razina značajnosti	0,05
Broj onih koji predviđaju	100
Veličina uzorka	105
Posredni izračuni	
Proporcija uzorka	0,9524
Standardna pogreška	0,0293
Testovna veličina z	1,7892
Test na gornju granicu	
Gornja kritična vrijednost	1,6449
p-vrijednost	0,0368
Odbacuje se nulta hipoteza	

Izvor: Izračun dobijen softverom PHStat2.

Dakle, polazne su hipoteze: $H_0 \dots p \leq 0,90$; $H_1 \dots p > 0,90$. Uz signifikantnost 5% i p-vrijednost=0.0386 nulta je hipoteza odbačena⁵. Time je potvrđena prva istraživačka hipoteza ovoga rada, pa se može reći da je predviđanje promjena u vlastitome poslovanju i poslovnome okruženju dio prakse velike većine (prema ovome testu, više od 90%) hrvatskih srednjih i velikih poduzeća. Dvodimenzionalna klasifikacija pokazuje da među istraživanim srednje velikim poduzećima njih 56,3% predviđa promjene za dvije godine ili duže, a među velikim poduzećima njih

⁵ Testiranje iste hipoteze uz razinu signifikantnosti od 1% dovelo bi do zaključka da nema dovoljno dokaza za odbacivanje nulte hipoteze, ali bi test uz hipoteze $H_0 \dots p \leq 0,80$; $H_1 \dots p > 0,80$ uz 1% značajnosti pružio dokaze za odbacivanje nulte hipoteze (uz testovnu veličinu $z=3,9036$ i p-vrijednost=0.0001).

84% predviđa za isto razdoblje. Proveden je hi-kvadrat test neovisnosti obilježja «veličina poduzeća» i «predviđanja promjena za dvije godine ili za duže za barem neki aspekt». Taj je test, uz empirijski hi-kvadrat=9,878 i 1 stupanj slobode, doveo do odbacivanja nulte hipoteze, pa je tako potvrdio da na razini signifikantnosti od 1% postoji statistički značajna ovisnost među ispitivanim obilježjima. Drugim riječima, može se zaključiti da je i razlika netom spomenutih postotaka statistički značajna, tj. u Hrvatskoj velika poduzeća u većoj mjeri predviđaju promjene za dvije godine ili duže za bar neki aspekt od srednje velikih poduzeća.

Dalje su ispitanici iz poduzeća koja se koriste predviđanjem promjena u okruženju i u poslovanju zamoljeni da navedu nositelje izrade predviđanja: unutar ili izvan poduzeća. Od 100 poduzeća koja predviđaju promjene, njih 86% predviđanja izrađuju samostalno, a 14% ih pri izradi predviđanja koristi pomoć vanjskih stručnjaka ili konzultanata (tablica 4). Uz razinu pouzdanosti od 95% očekuje se da se postotak hrvatskih velikih i srednjevelikih poduzeća koja samostalno izrađuju predviđanja promjena u okruženju u vrijeme istraživanja nalazi između 79,2% i 92,8%.

Tablica 4.

SAMOSTALNOST IZRADU PREDVIĐANJA PROMJENA U OKRUŽENJU
KOJIMA SE KORISTI ZA IZRADU STRATEŠKOG PLANIRANJA
(N=100, PODUZEĆA KOJA PREDVIĐAJU PROMJENE)

Nositelj izrade predviđanja	Broj odgovora	Struktura u %
Samostalno izrađuju predviđanja	86	86%
Ne izrađuju samostalno predviđanja	14	14%
Ukupno	100	100%

Izvor: Originalno anketno istraživanje.

Da bi se dobio uvid u značaj i donekle i u troškove izrade predviđanja, ispitanicima je postavljeno pitanje o izvorima podataka kojima se koriste. To je pitanje postavljeno samo onim ispitanicima u čijim se poduzećima samostalno izrađuju prognoze (n=86). Rezultat ispitivanja pokazao je da se 3,7% (od njih 86) ispitanika najčešće služi podacima iz publikacija vezanih uz branšu, a 69% njih podacima iz dnevnoga tiska i elektronskih medija. U isto se vrijeme njih 62% za potrebe predviđanja koristi i posebnim studijama, analizama i istraživanjima.

Tablica 5.

NAJČEŠĆE KORIŠTENI IZVORI PODATAKA PRI SAMOSTALNOJ
IZRADI PREDVIĐANJA PROMJENA U OKRUŽENJU KOD
ANKETIRANIH PODUZEĆA (N=86, PODUZEĆA KOJA
SAMOSTALNO PREDVIĐAJU PROMJENE)

Izvor podataka za izradu predviđanja	Broj odgovora	Udio u ukupnom broju poduzeća (n=86)
Publikacije vezane uz branšu	60	70%
Dnevni tisak i elektronski mediji	59	69%
Posebno izrađene studije, analize i istraživanja	53	62%
Posebne povremene publikacije i časopisi	49	57%
Interni podaci	9	10%
Kontakti sa stručnjacima	6	7%
Sve navedeno	5	6%
Statistički zavod	2	2%
Neovisni izvori	1	1%
Trenutna gospodarska politika	1	1%
Seminari, kongresi	1	1%
Službeni podaci	1	1%
Svjetski trend	1	1%

Izvor: Originalno anketno istraživanje.

Slijedećim pitanjem pokušalo se pretpostaviti razloge izostanka prakse samostalnog predviđanja (Tablica 6). To je pitanje postavljeno onim ispitanicima koji ne izrađuju predviđanja samostalno (n=14). Tako je od ukupno 14 ispitanika koji ne izrađuju predviđanja samostalno više od polovine kao najčešći odgovor dalo onaj o nedovoljnoj stručnoj opremljenosti, a slijedi visoka cijena izrade samostalnih predviđanja.

Tablica 6.

**NAJČEŠĆI RAZLOZI ZBOG KOJIH SE SAMOSTALNO
NE IZRAĐUJU PREDVIĐANJA**

Razlozi zbog kojih ispitanici samostalno ne izrađuju predviđanja	Broj odgovora	Struktura u %
Nedovoljna stručna opremljenost	8	57%
Visoka cijena izrade samostalnih predviđanja	3	21%
Zbog konkurencije	1	7%
Ne znam	2	14%
Ukupno	14	100%

Izvor: Originalno anketno istraživanje.

Ispitanici su zamoljeni da procijene u kojem vremenskom horizontu predviđaju promjene u sociološkom, ekonomskom, tehnološkom i političkom okruženju. Pitanje je postavljeno samo onim ispitanicima iz poduzeća koja samostalno izrađuju predviđanja (n=86). Prema tablici 7. promjene u sociološkom okruženju predviđaju se češće za razdoblje do jedne godine (49%), a nešto rjeđe za razdoblje od dvije ili više godina. Promjene u ostalome okruženju predviđaju se češće za razdoblje od dvije ili više godina (ekonomsko okruženje – 62%, tehnološko okruženje – 54% i političko okruženje – 38%), a rjeđe za razdoblje do jedne godine (ekonomsko okruženje – 36%, tehnološko okruženje – 35% i političko okruženje – 32%).

Tablica 7.

**ASPEKTI OKOLINE PO VREMENSKOM HORIZONTU PREDVIĐANJA
PROMJENA U OKRUŽENJU (N=86 ONIH KOJI
SAMOSTALNO PREDVIĐAJU)**

Vrsta okoline	Do 1 godine	2 ili više godina	Bez odgovora	Ukupno
Sociološka okruženja	49%	35%	16%	100%
Ekonomsko okruženje	36%	62%	2%	100%
Tehnološko okruženje	35%	54%	11%	100%
Političko okruženje	32%	38%	30%	100%

Izvor: Originalno anketno istraživanje.

Tablica 8.

**NAJČEŠĆE KORIŠTENNA PREDVIĐANJA VEZANA UZ POSLOVNO
 OKRUŽENJE KOD ANKETIRANIH PODUZEĆA (N=100 ONIH
 KOJI SE KORISTE PREDVIĐANJIMA)**

Predviđanja vezana uz poslovno okruženje	Broj odgovora	Udio u ukupnom broju poduzeća (n=100)
Predviđanja prodaje	80	80%
Predviđanja financijskih rezultata poslovanja	77	77%
Predviđanja troškova	76	76%
Udio Vaše tvrtke na tržištu	65	65%
Poslovne aktivnosti	58	58%
Ostalo	7	7%
Ne znam	2	2%

Izvor: Originalno anketno istraživanje.

Osim predviđanja promjena u okruženju tvrtke, predviđanja se izrađuju i za područja uobičajenih poslovnih aktivnosti (Tablica 6). Tako su predviđanja, odnosno prognoza prodaje kod većine, ili kod njih 80%, navedena kao najčešći odgovor. Osim predviđanja prodaje, financijski rezultati poslovanja (77%) i troškovi (76%) slijedeća su područja po učestalosti izrade predviđanja poslovnih aktivnosti anketiranih poduzeća. Udio tvrtke na tržištu predviđa 65% poduzeća.

**5.2. Metode predviđanja promjena u vlastitome
 poslovanju i u poslovnome okruženju**

Kojim se konkretnim metodama anketirana poduzeća koriste pri izradi predviđanja? Postavljeno je pitanje o najčešće korištenim kvalitativnim metodama predviđanja zatvorenoga tipa.

Kao što se vidi iz tablice 9., anketirana su poduzeća navela četiri najčešće korištene kvalitativne metode ili metode predviđanja promjena u okruženju, a to su: istraživanje tržišta (kod njih 64%), osobna procjena (61%), procjena stručnjaka (45%) i panel-konzensus metoda (42%). Osim navedene četiri najčešće korištene metode, anketirana poduzeća učestalo koriste i procjenu sila prodaje, povijesnu analogiju i metodu analize scenarija.

Tablica 9.

NAJČEŠĆE KORIŠTENE KVALITATIVNE METODE PREDVIĐANJA
PROMJENA U OKRUŽENJU KOD ANKETIRANIH PODUZEĆA
(N=100 ONIH KOJI PREDVIĐAJU)

Najčešće korištene kvalitativne metode predviđanja	Udio u ukupnom broju poduzeća (n=100)
Istraživanja tržišta	64%
Osobna procjena	61%
Procjena stručnjaka	45%
Panel-konsenzus metoda	42%
Procjena sila prodaje	37%
Povijesna analogija	34%
Scenarij metoda	16%
S-krivulja rasta	15%
Delfi metoda	12%
Ne znam	7%
Ostalo	5%

Izvor: Originalno anketno istraživanje.

Provedeni su z testovi o pretpostavljenim proporcijama populacija uz pretpostavku da je udio poduzeća koja se koriste istraživanjem tržišta i udio poduzeća koja rabe osobne procjene veći od 50%, tj.: $H_0 \dots p \leq 0,50$; $H_1 \dots p > 0,50$. Za obje metode predviđanja nije prikupljeno dovoljno dokaza da bi nulta hipoteza bila prihvaćena kao istinita. Tako je, uz 1% signifikantnosti potvrđena alternativna hipoteza koja tvrdi da se više od 50% poduzeća koristi istraživanjem tržišta (p-vrijednost=0,002) i uz 5% signifikantnosti da se više od 50% poduzeća koristi osobnom procjenom (p-vrijednost=0,013).

Dakle, rezultati istraživanja i testiranja statističkih hipoteza potvrđuju drugu hipotezu rada - da se hrvatska srednja i velika poduzeća najčešće koriste metodama istraživanja tržišta i osobne procjene kao osnovom predviđanja promjena u poslovanju i u poslovnome okruženju.

5.3. Povezanost oblika vlasništva nad poduzećem i predmeta predviđanja promjena u vlastitome poslovanju

Prema trećoj hipotezi ovoga rada pretpostavlja se da je predmet predviđanja poduzeća povezan sa prevladavajućim oblikom vlasništva, a to će se ispitati u ovome dijelu rada (tablica 10.). Predviđanje udjela na tržištu prilično se razlikuje prema prevladavajućem obliku vlasništva poduzeća. Udio na tržištu predviđa 33% državnih poduzeća, 44% poduzeća u mješovitom vlasništvu i 75% poduzeća u privatnome vlasništvu. Prognoziranje troškova i poslovne aktivnosti također se prilično razlikuje prema vlasništvu poduzeća.

Prodaju i financijski rezultat predviđa približno isti postotak poduzeća, bez obzira na prevladavajući oblik vlasništva. Prodaju predviđa 67% državnih poduzeća, 78% mješovitih poduzeća i 84% poduzeća u privatnome vlasništvu, a omjeri su približno isti za financijski rezultat.

Tablica 10.

BROJ I RELATIVNI UDJELI PODUZEĆA KOJA PREDVIĐAJU ODREĐENI ASPEKT PROMJENA U VLASTITOME POSLOVANJU

Prevladavajući oblik vlasništva		Predviđanje				
		Tržišni udio	Prodaja	Troškovi	Poslovna aktivnost	Financijski rezultat
Državno	n=18	6	12	9	7	12
	%	33%	67%	50%	39%	67%
Mješovito	n=9	4	7	6	2	7
	%	44%	78%	67%	22%	78%
Privatno	n=73	55	61	61	49	58
	%	75%	84%	84%	67%	79%
Ukupno		65	80	76	58	77

Izvor: Originalno anketno istraživanje.

Proveden je hi-kvadrat test neovisnosti između mogućih predmeta predviđanja i oblika vlasništva poduzeća. Prema tablici 11., uz razinu signifikantnosti od 1%, testiranje je pokazalo da postoji statistički značajna ovisnost za predviđanje udjela tvrtke na tržištu (p-vrijednost=0,001), troškova (p-vrijednost=0,009) i poslovnih aktivnosti (p-vrijednost=0,007). Time se može zaključiti da je opravdano

djelomično prihvatiti treću hipotezu da postoji veza između oblika vlasništva nad poduzećem i predmeta predviđanja promjena u poslovanju.

Tablica 11.

HI-KVADRAT TESTOVI ZA PREVLADAVAJUĆI OBLIK VLASNIŠTVA I
PREDMET PREDVIĐANJA ODREĐENOG ASPEKTA PROMJENA
U VLASITOME POSLOVANJU

Predmet predviđanja	Pearsonov hi-kvadrat	Stupnjevi slobode	p-vrijednost
Udio tvrtke na tržištu	13,038	2	0,001 *
Predviđanje prodaje	2,607	2	0,272
Predviđanje troškova	9,389	2	0,009 *
Predviđanje poslovnih aktivnosti	9,922	2	0,007 *
Predviđanje financijskih rezultata	1,336	2	0,513

Napomena: *visoka statistička značajnost (uz signifikantnost od 1%)

Izvor: Originalno anketno istraživanje.

6. Zaključak

U radu su opisane karakteristike predviđanja promjena u poslovnome okruženju i u vlastitom okruženju poduzeća. Ukratko su opisane metode predviđanja kojima se najčešće koristi: (1) subjektivne metode predviđanja, (2) istraživačke ili eksplorativne metode, (3) normativne prognostičke metode i (4) S-krivulje rasta. Da bi se ispitala praksa predviđanja promjena u poslovnome okruženju i u vlastitome okruženju velikih i srednjih hrvatskih poduzeća, provedeno je anketno istraživanje na uzorku od 112 poduzeća. Osnovni cilj istraživanja bio je odgovoriti na slijedeća pitanja: (1) predviđaju li hrvatska srednja i velika poduzeća budućnost? (2) kojim se metodama pritom koriste i kako organiziraju predviđanje u poduzeću? i (3) utječe li oblik vlasništva na predmet predviđanja promjena u poslovanju.

Rezultati istraživanja potvrdili su da hrvatska velika i srednjevlika poduzeća u većini slučajeva izrađuju predviđanja promjena, pri čemu to najčešće čine samostalno. Za izradu predviđanja najčešće se koriste vanjskim izvorima informacija, a najčešće korištene metode jesu istraživanje tržišta i osobna procjena. Poduzeća u najvećem broju slučajeva prognoziraju promjene u ekonomskom okruženju, u pro-

daji, financijske rezultate poslovanja i troškove. Konačno, postoji razlika između poduzeća s prevladavajućim državnim, mješovitim i privatnim vlasništvom i predmeta predviđanja promjena u poslovanju. Privatna poduzeća u odnosu na državna i mješovita poduzeća češće predviđaju poslovnu aktivnost i financijski rezultat.

Time su rezultati ovog izvornog znanstvenog istraživanja: (1) potvrdili prvu hipotezu rada da je predviđanje promjena u vlastitome poslovanju i u poslovnome okruženju dio prakse hrvatskih srednjovelikih i velikih poduzeća; (2) potvrdili drugu hipotezu rada da se hrvatska srednja i velika poduzeća najčešće koriste metodama istraživanja tržišta i osobne procjene kao osnovom za predviđanje i (3) djelomično potvrdili treću hipotezu rada da postoji veza između oblika vlasništva nad poduzećem i predmeta predviđanja promjena u poslovanju.

Zaključci ovoga rada ograničeni su činjenicom da su iz istraživanja isključena hrvatska mala poduzeća, pa autori u budućem znanstvenoistraživačkom radu namjeravaju istražiti i taj stratum u gospodarstvu veoma zastupljenih jedinica mogućega promatranja.

LITERATURA

1. Albright, R. (2002.). "What can past technology forecast tell us about the future?". *Technological Forecasting and Social Change*, Volume 69, pp.443-64.
2. Buble, M. (1997.). *Strategijski management*. Split: Ekonomski fakultet.
3. Cox, B. G., Binder, D. A., Chinappa, B. N., Colledge, M. J., Kott, P. (1995). *Business Survey Methods*. New York: Wiley.
4. Ćurlin, S. (2006.). *Primjena metoda predviđanja u strateškom planiranju hrvatskih poduzeća*. Magistarski rad. Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu.
5. DeLurgio, S.A. (1998.). *Forecasting principles and applications*. Boston: Irwin/McGraw Hill.
6. Godet, M. (1987.). *Scenarios and Strategic Management*. London: Butterworth.
7. Linstone, A., Turoff, M. (2002.). *The Delphi Method: Technique and Applications*, Dostupno na: www.is.njit.edu/pubs/delphibook/
8. Makridakis, S., Wheelwright, S.C., Hyndman, R.J. (1998.). *Forecasting Methods and Applications*. New York: Willey.
9. Makridakis, S. (1996.). "Forecasting: its role and value for planning and strategy", *International Journal of Forecasting*, Volume 12, pp. 513-537.

10. McClave, J.T., Benson, P.G., Sincich, T. (2005.). *Statistics for Business and Economics*. 9th Ed., Upper Sadle River: Prentice Hall.
11. Moutinho, L., Goode, M., Davies, F. (1998.). *Quantitative Analysis in Marketing Management: Concepts and Techniques*. New York: Wiley.
12. Pearce II, J.A., Robinson, R.B. (2000.). *Strategic Management: Formulation, Implementation and Control*. Boston: McGraw Hill.
13. Porter, A.L., Roper, A.T., Mason, T.W., Rosini, F.A., Banks, J. (1991.). *Forecasting and Management of Technology*. New York: Wiley.
14. Ringland, G. (1998.). *Scenario Planning. Managing for the Future*. New York: Wiley.
15. Schwartz, P. (1996.). *The Art of the Long View: Planning for the Future in an Uncertain World*. New York: Currency Doubleday.
16. Sterman, J. D. (1994.). *Modeling for Learning Organizations (System Dynamics Series)*. Portland, Or.: Productivity Press.
17. Žugaj, M., Dumičić, K., Dušak, V. (2006.). *Temelji znanstveno-istraživačkog rada. Metodologija i metodika*. Drugo, dopunjeno i izmijenjeno izdanje. Varaždin: Fakultet informatike i organizacije, Sveučilište u Zagrebu.

SURVEY RESEARCH ON CROATIAN ENTERPRISES' PRAXIS OF PREDICTING THE CHANGES IN BUSINESS MAKING AND BUSINESS ENVIRONMENT

Summary

Large number of changes in short time has become part of the modern business making for most of the firms. Correct prediction of the changes in business environment and firm's business making has become more and more important for the firm's management. Prediction was defined as impact estimation of external and internal factors to the future business making of the firm with the usage of qualitative methods based on the subjective estimation. Goals of the paper were: (1) to present methods of predicting the business environment and firm's business making, and (2) to estimate which prediction methods and in what ways were used in Croatian large and middle-sized firms. Survey based on Croatian enterprises sample revealed that Croatian large and middle-sized firms in most of the cases used to make predictions of changes by their own staff, with the usage of external information sources, market research and subjective estimation. The difference between firms based on their ownership was found. Private firms used to make different foresight of business making compared to public firms and firms with mixed private-public ownership.

Key words: predictions, sample survey, qualitative methods, judgmental prediction methods.