

Lovorka Galetić*
Jasna Prester**

UDK 338.36:338.27 (497.5)
JEL Classification O140, C53
Pregledni rad

EUROPSKA PROIZVODNJA I HRVATSKA DO 2020.¹: PROGNOZA MANVIS DELPHI ISTRAŽIVANJA^{2,3}

Predviđanje je osnovni alat za strateško i taktičko planiranje. Predviđanjem se kompanije, pojedinci ili cjelokupne države mogu pripremiti za događaje koji dolaze. Upravo zbog takvih pobuda Europska je komisija u prosincu 2003. godine pokrenula projekt MANVIS – Manufacturing Visions da bi podrobno ispitala koje su perspektive europske proizvodnje.

MANVIS je zamišljen kao sveobuhvatno istraživanje razvitka koncepata – od proizvodne tehnologije do organizacijskih koncepata. Istraživanje je podijeljeno u deset glavnih kategorija. Njima se prije svega željelo istražiti vremenski horizont realizacije i upotrebe pojedinog koncepta u masovnoj proizvodnji i zaostaje li Europa za ostalim svjetskim silama, kao što su npr., Amerika ili Japan. U istraživanju sudjeluju 22 europske zemlje, a kao i u mnogim dugoročnim istraživanjima (vremenski je horizont 20 godina) koristilo se Delphi metodom.

Rezultati su iznimno zanimljivi, i to oni općeniti na europskoj razini i oni u usporedbi s odgovorima samo iz Hrvatske. Glavni problem koji muči Europu

* L. Galetić, redovita profesorica na Ekonomskom fakultetu Sveučilišta u Zagrebu

** J. Prester, mr. sc., asistentica na Ekonomskom fakultetu Sveučilišta u Zagrebu. Prva verzija rada u Uredništvo primljena je 15. 6. 2005., a definitivna 27. 3. 2006.

¹ Ovaj je rad izrađen u sklopu internog projekta Ekonomskog fakulteta u Zagrebu

² MANVIS (Manufacturing Visions) jest Delphi istraživanje pokrenuto na inicijativu nekoliko vodećih europskih instituta, a financira ga Europska komisija da bi se dobili inputi za dugoročno planiranje sredstava za istraživanje i razvitak u područje proizvodnje. Službena stranica ovoga projekta glasi <http://www.manufacturing-visions.org/de/content/about.html>, ili na stranici Europske komisije – Joint Research Center, http://projects.jrc.cec.eu.int/show.gx?Object.object_id=PROJEC TS000000000048735

³ Zahvaljujemo recenzentima za ukazane nejasnoće koje smo u ovoj verziji ispravili.

jest problem premještanja proizvodnje u područja s manjim troškovima radne snage i s nižim ekološkim standardima.

Drugo vrlo važno pitanje bilo je: kako povećati konkurentnost europske privrede? Proizašlo je da bi, ako se želi slijediti američki primjer, bilo potrebno više ulagati u razvitak i u upotrebu inteligentnih i nanomaterijala. Kao potencijalne prepreke takvom razvitku stručnjaci ističu ekonomsku održivost i tehnološku provedivost, a tek je na trećem mjestu nedostatak ulaganja u istraživanje i razvitak.

Na posljepku bismo se željeli osvrnuti na probleme koji muče hrvatski proizvodni sektor. To se ponajprije odnosi na ulogu države u zaštiti i pomoći hrvatskome poduzetništvu, na potrebu stalnog obrazovanja, na potrebu primjene novih tehnologija i na važnost inovacija. Glavne prepreke rješavanju ovih problema stručnjaci vide u zakonima, a onda i u nedostatku kvalificiranih ljudskih potencijala. Smatramo da bi se većim investiranjem u istraživanje i razvitak u proizvodnom sektoru i u istraživačkim institucijama, povećala mogućnost inovacija, pa time i konkurentnost, ali se to ne može postići bez vrhunskog kadra.

Ključne riječi: Predviđanje, europska proizvodnja, Delphi metoda, proizvodne vizije

Uvod

Je li globalizacija prijatnija europskoj proizvodnji? Što se događa s europskom proizvodnjom i prijete li Europi poplava kineskih proizvoda? Postaje li premještanje europske proizvodnje u područja jeftinije radne snage zaista ozbiljan problem i kako će se Europa obraniti i pripremiti za sve te izazove (Fernández-Palomero Morales D., 2004.)? Globalizacija zahtijeva od poduzeća da budu konkurentna na globalnoj razini i nije više dovoljna samo lokalna konkurentnost (Pun i dr., 2004). Predviđanje je jedan od načina da se kompanije, pojedinci ili cjelokupne države pripreme za događaje koji dolaze. Predviđanje nije nikada stopostotno sigurno, uvijek postoji neizvjesnost – ali pomaže u planiranju i u strategijskoj orijentaciji poduzeća danas. Postoje čak i tvrdnje da predviđanjem i djelovanjem u skladu s tim predviđanjima kreiramo vlastitu budućnost (Walonick, 2004.). Sve više istraživanja pokazuje da globalizacija za pojedina područja ima negativne efekte, pa znanstvenici upozoravaju svoje državne institucije da poduzmu odgovarajuće mjere (Czinkota, Ronkainen, 2005.). Upravo je zbog takvih pobuda Europska komisija pokrenula projekt MANVIS – Manufacturing Visions- u prosincu godine 2003., i to da bi podrobno ispitala koje su mogućnosti europske proizvodnje. Rezultati toga istraživanja

postat će osnova na kojoj će planirati sredstva za istraživanje i razvitak u području proizvodnje. Taj bi projekt morao Europskoj komisiji osigurati input na osnovi kojeg će Komisija davati poticajna sredstva pojedinim zemljama za razvijanje proizvodnje tako da bi Europa zadržala svoje proizvodne konkurentske prednosti, a upravo je proizvodnja jedan od izvora konkurentske prednosti neke zemlje. Zemlje kojih proizvodnja bude pratila razvitak tehnologije bit će konkurentnije. Poduzeća će opstati samo ako se uspijevaju prilagoditi stalno mijenjajućem okruženju (Tracey, Vonderembse, Lim, 1999.), a sve to utječe na gospodarstvo cijele zemlje. Ovo je istraživanje bitno za Hrvatsku, i to zato da bi prepoznala svoj položaj u odnosu na ostale europske zemlje.

Slična istraživanja provode Kanada (Loo, 2002.) i Amerika (National Academy of Sciences, 2004.), Japan i Koreja (Shint, 1998.), pa je logično da i Europa mora istražiti svoje mogućnosti u odnosu prema ostalim svjetskim silama.

MANVIS je zamišljen kao sveobuhvatno istraživanje razvijanja koncepata – od proizvodne tehnologije do organizacijskih koncepata. Istraživanje je podijeljeno u deset glavnih kategorija. Ponajprije se željelo istražiti vremenski horizont realizacije i upotrebe pojedinog koncepta u masovnoj proizvodnji i istražiti zaostaje li Europa (pa time i Hrvatska) za ostalim svjetskim silama kao što su Amerika ili Japan.

U ovom se dugoročnom istraživanju (vremenski je horizont dvadeset godina) koristilo Delphi metodom. Ona ima svoje specifičnosti, a njih ćemo opisati u poglavlju metodologije.

Samo istraživanje odvijalo se u tri faze i trenutno smo u ovoj trećoj fazi. Prva se faza sastojala u tome da je tim stručnjaka iz osam najistaknutijih europskih institucija⁴ koje se bave dugoročnim istraživanjima predložilo više od 130 tvrdnji koje su stručnjaci na razini zemalja sudionika morali ocjenjivati. Organizirane su nacionalne radionice u 22 zemlje sudionice projekta, a na njima su davani prijedlozi za preformulaciju teza. Po konačnom su usuglašavanju teza te teze dane stručnjacima na ocjenjivanje. Struktura stručnjaka koji su ocjenjivali teze bila je ovakva: 40% iz akademskih krugova i ostatak iz proizvodnje. Nakon analize prvoga kruga istraživanja, proizašle su 22 tvrdnje kojima nije postignut konsenzus mišljenja stručnjaka i one su poslane u drugi krug. Projekt je trenutno u fazi izvođenja drugog Delphi kruga. U ovome se radu prije svega želimo osvrnuti na poziciju Hrvatske u odnosu na ostale europske zemlje i eventualno sugerirati kako bi hrvatska poduzeća povećala svoju konkurentsku prednost. Glavna je hipoteza rada da hrvatska proizvodnja zaostaje za europskom proizvodnjom. U svrhu odbacivanja ili prihvaćanja hipoteze iznose se rezultati za Hrvatsku koji će biti uspoređeni s rezultatima dobijenima na razini 22 zemlje sudionice. Hipoteza će biti provjerena na osnovi horizonta šire upotrebe tehnologija koje će najbrže biti uvedene u širu primjenu u Europi.

⁴ <http://pi.ijs.si/pibrain.exe?Cm=Project&Project=MANVIS&Reference=507139>

Rad je strukturiran tako da se prvo obrazlaže značaj predviđanja za poduzeća, i to zbog dvaju razloga. Prvi je taj što je gospodarstvo ipak to koje pospješuje konkurentnost zemlje, a drugi je taj da rezultati mogu poslužiti kao polazište za predviđanje na razini poduzeća. Osim što se rezultatima može koristiti za dugoročno predviđanje, oni mogu biti i poticaj gospodarstvu i državi za odluku u kojem smjeru da ulaže svoja sredstva za istraživanje i razvitak.

Slijedi metodologija, a rezultati su izneseni u tri skupine: prvo, na razini Europe s usporedbom s Amerikom i Japanom; drugo, na razini Hrvatske u usporedbi s Europom i na kraju slijede hrvatski specifični problemi. Cijeli se rad ponovno rezimira u zaključku.

Važnost predviđanja u strateškoj orijentaciji poduzeća

Dobra je prognoza iznimno važna za efikasnost i za efektivnost proizvodnje. Predviđanje je osnovni alat za strateško i taktičko odlučivanje (Waddell, Sohal, 1994.). Ono je posebno važno za svako poduzeće i za svaku bitnu menadžersku odluku; ono je osnova dugoročnog planiranja svakoga poduzeća. U funkcijskim odjelima, kao što su financije i računovodstvo, predviđanje je podloga za određivanje budžeta i za kontrolu troškova. Marketing se, npr., zasniva na predviđanjima o novim proizvodima, pa se na osnovi toga izrađuju marketinški planovi, planovi nagrađivanja zaposlenih u prodaji i dr. Proizvodnja se zasniva na prognozama za odabir procesa, na planiranju kapaciteta, prostornom rasporedu tvornice, na samome planu proizvodnje, terminiranju i potrebnim zalihama (Chase, Aquilano, Jacobs, 2001.). Ono je bitno i zbog ulaganja u nove tehnologije. Istraživanja pokazuju da poduzeća koja ulažu u nove tehnologije imaju znatnu konkurentsku prednost u odnosu na ona koja ne ulažu (Tracey, Vonderembse, Lim, 1998.). Rezultati takvih Delphi istraživanja izravno utječu na razvitak ili na procedure za razvitak organizacijskih koncepata i politika, na procedure za umanjivanje ili izbjegavanje potencijalnih predviđenih negativnih efekata (Loo, 2002.).

Rezultat je strateške orijentacije poduzeća plan – popis aktivnosti ili vodič koji će pomoći da se stigne do cilja. Po definiciji strategijska orijentacija ima dvije karakteristike – nju se određuje unaprijed prije nego što se događaj dogodio i izgrađuje se svjesno (Mintzberg, Lampel, Quinn, Ghosal, 2003.). Prvi korak u formuliranju strategije jest identificirati prilike i prijetnje iz okruženja. Na osnovi tih identificiranih prilika i prijetnji rade se prognoze, što je onda osnova za planove potrebnih resursa, materijala, ljudskog potencijala i financijskih sredstava. Upravo u tim planovima predviđanje ima ključnu ulogu zato što se radi o događajima koji će se tek dogoditi (Mintzberg, Lampel, Quinn, Ghosal, 2003.). Predviđanje i strategijsko planiranje datira još od početka ljudske aktivnosti, ali se tada više

radilo na intuitivnoj osnovi, nego na osnovi sofisticiranih matematičkih modela (Kenneth, 1983.). Što je predviđanje točnije, poduzeće će biti bolje pripremljeno za uvjete koji dolaze. Drugo što valja imati na umu jest da je prognoza stalni proces. Kada je jednom završeno predviđanje, pa je na osnovi toga završeno planiranje i poduzete su akcije (npr. predviđa se smanjenje potražnje, napravljena je dodatna propaganda kako bi se kreirala dodatna potražnja i uposlio višak kapaciteta), mi smo time promijenili situaciju i zbog toga je potrebna nova prognoza. Prema tome prognoziranje nije statičko, ono je iterativni proces, ako se želi opstati u turbulentnom okruženju. Prema Kennethu planiranje je osobito bitno kada se radi o kompleksnim poslovima, stalnim promjenama, o neizvjesnosti i o neefikasnim tržištima. Predviđanje je u tim situacijama procedura pretvaranja sadašnjih informacija o stanju okruženja u informacije o budućim rezultatima na osnovi kojih će se raditi planovi. Konkretno, za proizvodno će poduzeće to značiti hoće li kupiti dodatni kapacitet, zaposliti dodatne ljude, nabaviti materijale i sl. No, greške su u predviđanju skupe (neiskorišteni kapacitet, zastarjele zalihe koje se ne mogu prodati), pa se zato metode predviđanja i informacije na osnovi kojih se predviđa stalno usavršavaju (Armstrong, 1978.). Nažalost, okruženje poduzeća stalno se mijenja i, što se radi o dužem vremenskom razdoblju za koje se obavlja predviđanje, pogreške su veće. «Vizionari» koji mogu predvidjeti budućnost na osnovi intuicije postoje (Wit, Meyer, 1998.), ali sve veći broj kompanija svoja predviđanja ipak zasniva na različitim znanstvenim metodama.

Potrebno je reći da predviđanje ima neke svoje specifične karakteristike; predviđanja nisu nikada stopostotno točna. Točnija su kratkoročna, nego dugoročna predviđanja; bolja su predviđanja za grupe proizvoda, nego za pojedinačne proizvode; predviđanje će biti pogrešno ako se zasniva na lošim ili neispravnim informacijama (Chopra, Meindl, 2004.).

Metoda istraživanja

Delphi istraživanje kojim se koristi u ovom sveobuhvatnom Projektu sustavan je, iterativni proces koji nastoji otkriti sporazumno mišljenje velike skupine stručnjaka. Delphi metoda pripada kvalitativnim vrstama predviđanja, kojima se posebno koristi kada ne postoje relevantni podaci, kao što je slučaj u predviđanju budućnosti razvitka novih tehnologija ili sl. Delphi metoda, osim predviđanja, nastoji razumjeti i faktore koji utječu na odlučivanje u konkretnome području. Snažna je prednost Delphi metode to što se ona zasniva na mišljenjima velikog broja stručnjaka, čime se postiže točnija prognoza od, recimo, mišljenja samo jednoga stručnjaka. Ona se razlikuje od drugih metoda zasnovanih na mišljenjima stručnjaka po tome što stručnjaci ne utječu jedni na druge i međusobno ne komuniciraju, pa

tako jedan ne utječe na mišljenje drugoga. Taj pristup smanjuje mogućnost prevladavanja jednoga mišljenja i razvija suglasnost mišljenja stručnjaka, o tvrdnjama na koje se daje subjektivan odgovor. Ne postoji jedinstveni stav o veličini skupine stručnjaka. Dok neki autori tvrde da uzorak mora biti mali, neka su istraživanja napravljena i na nekoliko tisuća ispitanika⁵. Općenito se smatra da klasične nasumične metode odabira ispitanika više nisu dobre kada se traži stručno mišljenje (Beretta, 1996.). Provedena Delphi istraživanja pokazuju da je kod većih uzoraka postotak «nesudjelovanja» u drugome krugu veći kod većih uzoraka nego kod manjih (Reid, 1988.). Razlika je od klasičnog kvantitativnog istraživanja upravo to što su stručnjaci svojevrijem pristali na istraživanje. Istraživanja također pokazuju da ovaj «samoizbor ili voljnost sudjelovanja» ne mijenja mišljenje (McKee, Priest, Ginzler, Black, 1991.).

Veliki je značaj metode to što se, ako se ne postigne suglasnost o nekom pitanju, stručnjacima obznanjuju ti kontradiktorni rezultati i postupak se ponavlja sve dok se mišljenja ne usuglase (MacCarthy, Atthirawong, 2003.).

Delphi metodom počelo se koristiti u pedesetim godinama u Americi, a svrha je bila ocijeniti vjerojatnost i moguće posljedice atomske bombe (Benson, Hill, Hoffmann, 1982.). Od tada do danas primjenjivana je u različite svrhe, i to ponajprije za predviđanje, za strateško planiranje, i za strateško planiranje lanca dobave. Kao posebno značajna istraživanja upotrebom Delphi metode MacCarthy navodi: Lynch i dr. 1994., Iverson i Jorgensen 1986., Ray i Sahu 1990., McKnight 1991., Harland 1999., Green i Price 2000. Mi bismo posebno izdvojili istraživanje skupine stručnjaka s National Academies pod naslovom «Visionary Manufacturing Challenges for 2020» (1998.), i to zato što je približno slično našem istraživanju, ali je to američko istraživanje.

Skupina stručnjaka ne odabire se nasumice, već to moraju biti stručnjaci koji imaju saznanja o području koje se proučava. Glavna je karakteristika Delphi metode prema Tavana (1996.) to da: (1) mora postojati anonimnost među stručnjacima, (2) mora se dobiti statistički značajan uzorak odgovora iz dobro formuliranog upitnika, i (3) moraju se dobiti kontrolirane povratne informacije (Tavana, Kennedy, Joglekar, 1996.). No, Tavana naglašava da je ključni dio procesa oblik i sadržaj upitnika.

Početni upitnik za ovo istraživanje izrađen je u Fraunhofer Institutu i zasnovan je na prethodnim istraživanjima i na postavljanju novih teza. U toj fazi sudjelovali su i stručnjaci prekomorskih zemalja da bi se izbjeglo izolirano mišljenje usmjereno

⁵ Vidjeti: Wild, C., Torgersen, H. (2000.), "Foresight in medicine: lessons from three European Delphi studies", *European Journal of Public Health*, Vol. 10 No. 2, str. 114-9 i Cantrill, J.A., Sibbald, B., Buetow, S. (1996.), "The Delphi and nominal group techniques in health services research", *International Journal of Pharmacy Practice*, Vol. 4 No. 2, str. 67-74. (Prema autorima zagovornici malih skupina zapravo ne razlikuju Delphi istraživanje od konvencionalnih kvantitativnih istraživanja)

samo na Europu. U istraživanju sudjeluju 22 zemlje: Austrija, Belgija, Bugarska, Hrvatska, Danska, Estonija, Finska, Francuska, Njemačka, Grčka, Mađarska, Italija, Nizozemska, Norveška, Poljska, Rumunjska, Slovačka, Slovenija, Španjolska, Švedska, Turska, Velika Britanija. U svibnju godine 2004. organizirane su nacionalne radionice u svakoj od navedenih zemalja. Na tim je skupovima detaljno obrađena svaka od 130 teza i sugeriralo se njihovo eventualno pojašnjenje, promjena ili izbacivanje. Isto je tako svaka od zemalja imala pravo sastaviti pet teza specifičnih samo za svoju zemlju. Teze su bile na engleskom jeziku i svaka je zemlja za potrebe svoje radionice morala teze prevesti na svoj jezik. Ocjenjivani su jasnoća teze i konzistentnost i sugerirane su promjene. Nakon rezultata svih radionica poslan je konačni izgled upitnika koji je ponovno, ali ovog puta «on-line», bilo potrebno prevesti da bi stručnjaci ocjenjivali teze na svom materinskom jeziku. Rezultat je bio izbacivanje gotovo trideset teza. Konačni se upitnik sastojao od 101 pitanja, a ta su pitanja grupirana u deset kategorija.

Usporedno se odvijao izbor stručnjaka koji će činiti skupinu. U tu je svrhu zamoljeno 500 proizvodnih poduzeća u Hrvatskoj da sudjeluju u istraživanju. Dobijeno je 60 suglasnosti. Osim toga, kontaktirani su i akademski krugovi s molbom za suradnju. Ponajprije su kontaktirani Strojarski fakultet u Zagrebu i Splitu i Prirodoslovno matematički Fakultet u Zagrebu. Te su adrese poslano u Fraunhofer Institut koji je zadužen za web podršku toga istraživanja. Cilj je bio da stručnjaci budu iz prakse, iz akademskih krugova i iz vladinih institucija. Usprkos evidenciji adresa stručnjaka na serveru, u uvodnom je dijelu istraživanja jasno naglašeno da su podaci o ispitanicima tajni i da je zajamčena privatnost. Anonimnost je bitan čimbenik u Delphi istraživanju, i to prije svega zato da bi stručnjaci dali svoje mišljenje, a ne da budu pod utjecajem nekog utjecajnog pojedinca. Prema tome, među sudionicima ne postoji povezanost, oni su nepoznati jedni drugima, ali postoji točna evidencija u Fraunhofer institutu o odgovorima pojedinoga stručnjaka. Takav je postupak omogućen informatičkom tehnologijom i on osigurava ono što se nekada smatralo nedostatkom u Delphi metodi, a taj je da se ne zna koji je odgovor čiji, stručnjaci se ne trude da daju svoja stvarna razmišljanja (Sackman, 1975.).

Prvi krug Delphi istraživanja krenuo je u rujnu godine 2004. tako da je web alat koji su kreirali programeri Fraunhofer instituta slano e-mail s automatskom vezom na istraživanje. To je dalo mogućnost stručnjaku da ne mora odjednom ispuniti cijeli upitnik. To se pokazalo osobito bitnim zato što je upitnik zaista bio dugačak. Druga pogodnost održavanja takve baze adresa jest da se moglo pratiti tko je ispunio, tko je počeo ispunjavati ili tko je samo pogledao anketu, pa je to dalo mogućnost da se pisma-podsjetnici šalju samo onima koji nisu do kraja ispuniti upitnik.

Na svako pitanje stručnjaku otvorio se ekran na kojem je (uglavnom Likertovim ljestvicama) valjalo ispuniti: kolika je njegova stručnost o toj problematici⁶,

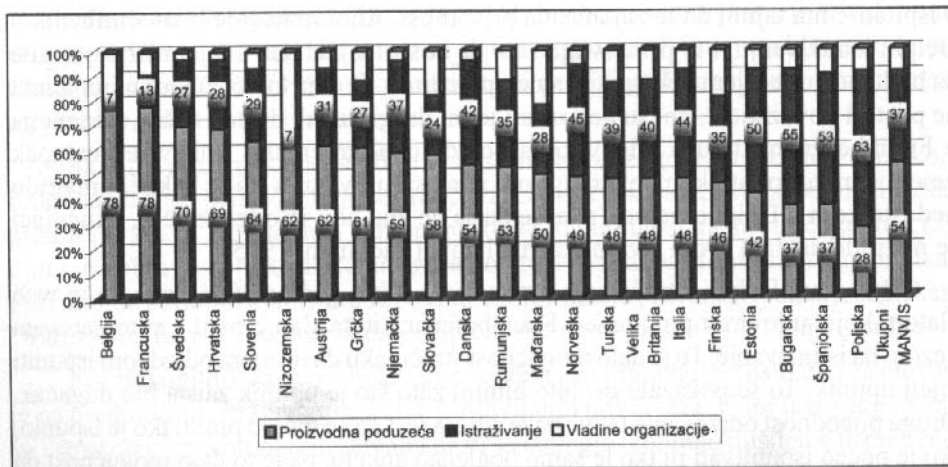
⁶ To je specijalni tip Delphi metode koja od ispitanika zahtjeva da ocijene svoju stručnost na ljestvici. Tim se podatkom koristi tek u drugome krugu. Vidjeti: Ishikawa, A., Amagasa, M., Shiga,

koje je procijenjeno vrijeme realizacije te tvrdnje, koliko je to važno za europsku proizvodnju, pozicioniranje vlastite zemlje u odnosu prema svjetskim silama (EU članovi, Amerika, Japan, Azija), očekivani efekti koje će izazvati upotreba te tehnologije (na okoliš, na regionalne razlike, na kvalitetu života, na zaposlenost, konkurentnost i dr.) i naposljetku koje su glavne prepreke za realizaciju pojedine tvrdnje. Po strukturi upitnika možemo prepoznati standardni okvir Delphi metode, a ona je veoma nalik korejskom Delphi istraživanju u kojem je u prvome krugu sudjelovalo 4500 stručnjaka (Shint, 1998.).

U prvome krugu istraživanja molba za suradnju u ovome istraživanju poslana je na 200 adresa (gospodarstvo, fakulteti, istraživačke institucije). Svaka je zemlja, da bi se stvorio reprezentativni uzorak, morala na svaki način osigurati minimalni broj odgovora. Za Hrvatsku donja je granica bila 60 odgovora. U prvome krugu dobili smo 66 potpunih odgovora, a to je veliki uspjeh ako se uzme u obzir da se radi o web anketi, što je zahtijevalo ne samo dobro poznavanje Interneta nego i stalnu vezu na Internet, jer je samo tako bilo omogućeno popunjavanje. Sveukupan je broj stručnjaka koji je sudjelovao 2993 (Dreher i dr., 2005.), što je veoma reprezentativan uzorak. Struktura ispitanika po zemljama dana je na slijedećoj slici:

Slika1.

DISTRIBUCIJA ODGOVORA STRUČNJAKA POJEDINE ZEMLJE



Izvor: http://www.manufacturing-visions.org/ManVis_Report_2_Final.pdf, str. 64

T., Tomizawa, G., Tatsuta, R. and Mieno, H. (1993.), "The maxmin Delphi method and fuzzy Delphi method via fuzzy integration", *Fuzzy Sets and Systems*, Vol. 55 No. 3, pp. 241-53. i Turoff, M. (1970.), "The design of a policy Delphi", *Technological Forecasting and Social Change*, Vol. 2 No. 2, pp. 149-71.

Na slici se vidi da su uglavnom odgovori pristigli iz poduzeća (54%), zatim iz istraživačkih institucija (37%), a najmanje iz različitih državnih institucija (9%). Za istraživanje konkretnih vizija za budućnost proizvodnje taj je uzorak od 54% proizvodnih poduzeća dobar. Također se mora naglasiti da je i Hrvatska prilično dobro pokrila zahtijevani omjer tj. barem 60 % odgovora iz industrije.

Povratna je informacija iznimno bitna, i to u obliku razumljivom na prvi pogled, a ne kompleksnom statistikom. Postoji, doduše, bojazan da slikovitim prikazu takva informacija (kada stručnjak otvori svoju stranicu dobiva sve odgovore u obliku grafikona, pa veoma brzo može uočiti podrobnosti) djeluje na mišljenje stručnjaka. Ipak, istraživanja su pokazala da je taj utjecaj mali (Scheibe, Skutsch, Schofer, 1975.). Trenutno se provodi drugi krug Delphi MANVIS istraživanja i rezultati su prikazani grafičkim distribucijama odgovora, što uvelike olakšava čitljivost rezultata prvoga kruga i motivira stručnjake da sudjeluju u drugome krugu.

Isto tako postoji neslaganje o broju krugova koje je potrebno provoditi, pa neki autori smatraju da se istraživanje mora nastaviti dok se god ne postigne konsenzus (Turoff, 1970., str. 161). Drugi autori smatraju da to iritira i izaziva stalno smanjenje broja odgovora (Selfe, 1996., str. 679). Mullen (2003.) na osnovi svoga istraživanja smatra da su za tehnološka Delphi istraživanja dovoljna dva kruga (Mullen, 2003.) koliko ih se provodi i u ovome istraživanju.

Rezultati istraživanja

Rezultate ćemo podijeliti u dvije tematske cjeline. U prvome dijelu bavit ćemo se najvažnijim otkrićima prvoga kruga istraživanja na razini svih zemalja sudionica, a u drugome dijelu usporediti te rezultate s odgovorima hrvatskih stručnjaka.

Rezultati istraživanja u Europi

Najveći značaj dobila je tvrdnja S045 (visoka automatizacija prevagnut će nad premještanjem proizvodnje u zemlje s jeftinijom radnom snagom). Stručnjaci predviđaju da se investiranjem u automatizaciju može značajno pojačati europska konkurentnost. Druga je po redu tvrdnja S022 (mreže malih poduzeća mogu uspješno konkurirati na svjetskoj razini). Drugim riječima, stručnjaci smatraju da nije potrebno imati velika poduzeća da bi se uspješno konkuriralo na svjetskoj razini. Treća je po redu tvrdnja S005 (mikro-električni uređaji koriste se po cijeloj tvornici). To se odnosi na različite aktivatore i senzore koji će biti u širokoj upotrebi. Četvrta po redu tvrdnja po svojoj značajnosti jest S046 (fiksni dio radnoga vremena

zaposlenici moraju iskoristiti za učenje). Ta tvrdnja uopće ne začuđuje zato što se tehnologija stalno razvija i zaposlenici to moraju pratiti. Teži se institucionalizaciji učenja, a ne da ono ovisi o samoinicijativnoj volji zaposlenika. Naposljetku, peta najznačajnija tvrdnja jest S030 (nano-materijali u širokoj su upotrebi, npr. samočišćenje, otpornost na udarce, sprečavanje pjenjenja). Stručnjaci smatraju da je potrebno više se koristiti tim materijalima da bi proizvodnja bila jeftinija, pa time i konkurentnija.

Tvrdnje koje su dobile najmanji značaj odnosile su se na radne uvjete (npr. rad kod kuće, projektni tip zapošljavanja, omjer žena u proizvodnji, utjecaj sindikata i sudjelovanje radnika u odlučivanju). Predviđa se da se poboljšanjem tih uvjeta rada neće značajno utjecati na konkurentnost proizvodnje. U dijelu koji slijedi više nećemo razmatrati te tvrdnje, nego ćemo se usredotočiti na one koje su ocijenjene kao najznačajnije.

Vrijeme realizacije

Više od 50% ispitanika predviđa da će se sve tvrdnje ispuniti u razdoblju između godina 2010-2020. Nažalost, široka primjena nano tehnologije (S030) u Europi, prema predviđanjima, neće se dogoditi prije 2020. Tvrdnje za koje stručnjaci predviđaju da će se najbrže ispuniti jesu S016 (podrobno specificiranje procedura proizvodnje), S017 (eksternalizacija djelatnosti koji nisu od strateškog značaja), S022 (unapređivanje razmjene znanja unutar kompanije) i S015 (timovi u kojima su radnici pogona koji mogu utjecati na plan i proizvodnju). Tvrdnja S016 uopće ne čudi zato što sve uspješne proizvodne tvrtke imaju ISO certifikate, koji između ostaloga, zahtijevaju rigoroznu dokumentaciju svih procesa (proizvodnih i administrativnih) unutar tvrtke; S017 također ne čudi, jer se uvidjelo da je zbog kvalitete i cijene obično bolje za tu djelatnost koja nije glavna unajmiti stručniju tvrtku, nego biti jako vertikalno integrirano poduzeće. S022 – unapređivanje razmjene znanja logično je, jer ono već postoji i potrebno ga je samo dijeliti, pa će se tako stvoriti dodatna znanja. Za to nisu potrebne velike investicije, pa se ta tvrdnja može relativno brzo realizirati. Tvrdnja S015 o davanju više ovlasti samim radnicima potekla je iz Amerike i Japana, a upućuje na to da je upravo radnik na stroju taj koji može najstručnije sugerirati promjene i izaći s novim efikasnijim rješenjima. Sve širom upotrebom Just-in-time sustava radnik zapravo i mora imati ovlasti u planiranju i u određivanju redoslijeda poslova.

Očekivani utjecaji

Za svaku tvrdnju stručnjaci su predviđali potencijalni učinak tvrdnje. Tako su se morali osvrnuti na to hoće li tvrdnja:

- poboljšati kvalitetu okoline
- poboljšati kvalitetu uvjeta rada
- povećati zapošljavanje
- povećati konkurentsku sposobnost
- povećati regionalnu prednost

Mi nećemo ulaziti u podrobnju analizu po svim pitanjima, nego ćemo se samo osvrnuti na konkurentnost i zapošljavanje kao goruće probleme.

Tablica 1.

POZITIVNI I NEGATIVNI UČINCI NA ZAPOSLENOST

| Zapošljavanje | |
|-------------------------------------|--|
| <i>Tri najjača pozitivna učinka</i> | <i>Tri najjača negativna učinka</i> |
| Osnivanje mreže malih poduzeća S022 | Premještanje proizvodnje izvan EU S039 |
| Lokalna proizvodnja S044 | Tvornice bez čovjeka S007 |
| Certifikacijski programi S047 | Premještanje zbog ekoloških razloga S042 |

Tablica 2.

POZITIVNI I NEGATIVNI UČINCI NA KONKURENTNOST

| Konkurentnost | |
|---|--|
| <i>Tri najjača pozitivna učinka</i> | <i>Tri najjača negativna učinka</i> |
| Osnivanje mreže malih poduzeća S022 | Premještanje proizvodnje izvan EU S039 |
| Pametni materijali ⁷ S028 | Restrikcije na kamionski prijevoz S038 |
| Rekonfigurabilni ⁸ proizvodni sustavi S009 | Premještanje zbog ekoloških razloga S042 |

⁷ Pametni su materijali oni koji u različitim uvjetima (tlak, temperatura, vlažnost,...) imaju drugačija svojstva. Ti se materijali prilagođuju okolini i udovoljavaju svojstvima koja se od njih traže.


⁸ Budući da se automatizacija i tehnologija sve brže razvijaju, prednost imaju strojevi i sustavi koji se mogu relativno brzo i jednostavno nadograditi ili eventualno reprogramirati

Primjećujemo da u obje kategorije mreže malih poduzeća potiču i konkurentnost i zapošljavanje. Sa druge strane premještanje proizvodnje izvan EU (bilo zbog troškova, bilo zbog visokih standarda zaštite okoliša) negativno djeluju i na zapošljavanje, i na konkurentnost. Tvrdnja S038 - restrikcije na kamionski prijevoz traži dodatno objašnjenje. Naime, da bi se smanjilo zagađenje, potiču se europski proizvođači da se više koriste alternativnim prijevozima – brod, vlak i sl.

Europska komisija pokrenula je projekt «Marco Polo» zbog nesrazmjera cestovnog i ostalih (ekološki prihvatljivijih) načina prijevoza. Tim se projektom želi vratiti atraktivnost prije svega željezničke industrije zato da se sačuvaju radna mjesta i da se prijevoz tereta i putnika (koji je u povećanju) obavlja ekološki prihvatljivijim sredstvima⁹.

Slika 2.

U OVOME JE TRENUTKU VELIKI NESRAZMJER IZMEĐU
UPOTREBLJENIH SREDSTAVA PRIJEVOZA¹⁰:



Prema izvještaju Europske komisije, ako se ništa ne poduzme, povećat će se prijevoz cestom za 50% u razdoblju do godine 2010. To će, sa druge strane, prouzročiti 50% povećanja emisije CO₂, a to povećava efekt staklenika. Osim toga je 70% goriva koji se troši na prijevoz iz uvoza, što je dodatni motiv Europskoj komisiji da se taj način prijevoza smanji. Ako se slika do godine 2010. uz «Marco Polo» program ne popravi, najavljuju se dodatne pristojbe na cestovni promet. To znači da poskupljuje kamionski prijevoz (a katkada je kamionski prijevoz jedino moguće), pa to onda djeluje na troškove i na konkurentnost poduzeća.

⁹ http://europa.eu.int/comm/energy_transport/library/press-kit-lben.pdf


¹⁰ http://europa.eu.int/comm/energy_transport/library/press-kit-lben.pdf, str. 6

Glavne prepreke

Za svaku tvrdnju stručnjaci su prognozirali koje su glavne prepreke za njezino izvođenje. Ponuđeno je pet mogućnosti: Obrazovanje/kvalifikacija, tehnička izvedivost, socijalna prihvatljivost, EU zakoni/standardi, ekonomska održivost, nedostatak investiranja u istraživanje i razvitak. Na naše veliko iznenađenje za većinu su tvrdnji stručnjaci utvrdili da je glavna prepreka ekonomska održivost, tj. da se dugoročno realizacija tih tvrdnji neće isplatiti. Slijedeća po redu jest tehnološka izvedivost, a tek je na trećem mjestu nedostatak investiranja u istraživanje i razvitak. Naše je viđenje da je baš nedostatak ulaganja u istraživanje i razvitak u odnosu na Ameriku i Japan glavni problem iz kojega onda slijede ova dva razloga koja su stručnjaci izdvojili kao glavne prepreke: ekonomska održivost i tehnička izvedivost. Tu tvrdnju dodatno potkrepljujemo napisima Europske komisije da bi razina ulaganja u istraživanje i razvitak do 2010. godine morala dostići 3% Europskog BDP.¹¹ Neovisna je analiza Europske komisije najvećih proizvođača i njihovih ulaganja u istraživanje i razvitak pokazala da Europa zaista zaostaje za Amerikom i Japanom.

Slika 3.

INVESTIRANJE NAJVEĆIH SVJETSKIH SILA



Izvor: http://eu-iriscoreboard.jrc.es/docs/scoreboard_2005_key%20findings.pdf, str. 5

¹¹ <http://www.euractiv.com/Article?tmuri=tcm:29-117437-16&type=LinksDossier>

To potkrepljujemo također i neovisnom prognozom Europske komisije koja kaže da bi se postizanjem 3% BDP za istraživanje i razvitak, BDP povećao za 0.5% i kreiralo bi se 400.000 novih radnih mjesta.¹²

Ekonomska održivost

Ekonomska održivost posebno se odnosi na to da pojedina tvrdnja nije dugoročno ekonomski isplativa ili uopće nije isplativa. Tri tvrdnje pogotovo pripadaju toj kategoriji, a to su:

S043 – industrijska se oprema ne kupuje, već se posuđuje, a dobavljaču opreme plaća se po proizvedenom dijelu (prema preliminarnim rezultatima takvim se aranžmanima koristi svega 4% njemačkih poduzeća i ona su zanimljiva proizvođačima, ali ne i dobavljačima opreme)

S037 – većina se proizvoda proizvodi lokalno multifunkcionalnom opremom (problem je to što se većina proizvoda ne proizvodi lokalno multifunkcionalnom opremom, već se uvozi, pa to Europu, jednako kao i Hrvatsku, najviše zabrinjava)

S038 – prijevoz vlakom i brodom prevladava nad kamionskim transportom (to bi EU voljela postići da bi se smanjilo zagađenje okoliša. Stručnjaci predviđaju da to ipak nije financijski opravdano).

Tehnička izvedivost

Posebno su tehnički neizvedive slijedeće tvrdnje:

S029 – broj materijala koji ide u proizvod prepolovljuje se (npr., izrada čipova – sve su manji i sve je manje materijala potrebno za njihovu izradu – ali prema mišljenju stručnjaka to ipak ne vrijedi za ukupnu proizvodnju)

S028 – široko su rasprostranjeni pametni materijali (to su materijali koji mijenjaju svojstva prema uvjetima u okolini)

S030 – široka upotreba nano materijala (nano materijali materijali su koji imaju dimenzije 10^{-9} mm. Takvim se materijalima posebno koristi u građevinarstvu da bi se postigla određena svojstva cementa, kao npr., brže stvrdnjavanje i veća čvrstoća, no takvi su materijali još uvijek preskupi da bi ušli u široku upotrebu).

¹² <http://www.europa.eu.int/invest-in-research/>

Iako je rečeno da su te dvije prepreke najznačajnije, smatramo da je opravdano nešto reći i o prepreci koju čini nedovoljno investiranje u istraživanje i razvitak. Posebno se to odnosi na tvrdnje:

S028 – široko su rasprostranjeni pametni materijali

S030 – široka upotreba nano materijala

S003 – proizvodi se mogu proizvoditi slaganjem slojeva atoma.

Vidimo da se ponavljaju dvije tvrdnje koje postoje i kod tehničke izvedivosti, a to potvrđuje naše mišljenje da je upravo nedostatak investiranja u istraživanje i razvitak rezultat tehničke neizvedivosti.

Tko najviše ulaže u istraživanje i razvitak

Pogledajmo kako stručnjaci ocjenjuju koje zemlje vode u ulaganju u istraživanje i razvitak i za koja područja. Predočujemo cijeli grafikon, ali smo za pojedinu zemlju uzeli samo po dvije tvrdnje. Rezultat je slijedeći:


Tablica 3.

U ŠTO TKO INVESTIRA

| Zemlja | Tvrdnje |
|--------|---|
| Europa | S011 ekološka proizvodnja S013 proizvodnja iz recikliranih materijala |
| USA | S004 Proizvodnja uz dodatak živućih organizama S003 Proizvodnja iz nano materijala |
| Japan | S007 Proizvodnja bez ljudi – robotika S006 Coboti (vrsta robota) |

Slika 4.

INVESTIRANJE U POJEDINA PODRUČJA



Izvor: http://www.manufacturing-visions.org/ManVis_Report_2_Final.pdf, str. 23


Ono što se osobito može primijetiti iz tablice 3. i slike 4. jest to da su se Europa, Japan i Amerika koncentrirali na ulaganja u sasvim druga područja. Europa najviše investira u ekološku proizvodnju i u recikliranje (S011 i S013), a Japan i Amerika tu veoma malo investiraju u odnosu na Europu. Vrijedi i obratno, gdje investiraju Japan i Amerika (Amerika u specijalne materijale, a Japan u robotiku) europsko je investiranje malo.

Na pitanje što bi najviše povećalo europsku konkurentnost, proizašle su četiri tvrdnje:

- S003 – proizvodnja od nano materijala
- S004 - proizvodnja s živućim organizmima
- S005 – mikroelektronički sklopovi
- S012 – tehnologije za brzu izradu

Slika 5.

VIZIJA UPOTREBE POJEDINE TEHNOLOGIJE Prognoza stručnjaka kada bi se te tehnologije uvele u praksu u Europi



Prema tome je, da bi se na takav način konkuriralo Americi - prema mišljenju stručnjaka, poželjno povećati investicije u istraživanje materijala sa specijalnim svojstvima (npr. u fundamentalne znanosti kao što su fizika i biologija) ili po uzoru na Japan u elektroniku.


Rezultati istraživanja na hrvatskome uzorku

U prethodnom smo dijelu analizirali mišljenje 2993 stručnjaka iz 22 zemlje i vidjeli smo koji su glavni problemi europske konkurentnosti i predviđanja kada će određene tehnologije ući u širu upotrebu. Obradujući rezultate samo za Hrvatsku, došli smo do zanimljivih saznanja.

Pitanje koje najviše muči Europljane jest mogu li se višom automatizacijom ostvariti veće uštede nego premještanjem pogona u jeftinije zemlje?

Slika 6.


PRETEŽE LI VISOKA AUTOMATIZACIJA NAD UŠTEDAMA
KOJE SE MOGU OSTVARITI PRESELJENJEM
PROIZVODNJE U JEFTINIJE ZEMLJE



Na slici 6. vidi se da većina stručnjaka u Hrvatskoj nije odgovorila na to pitanje. Razlog je veoma jednostavan: Hrvatska se barem zasad ne susreće s problemom premještanja pogona. To je problem ponajviše u Europi, gdje velike kompanije premještau svoje tvornice u Kinu i u slične zemlje s jeftinijom radnom snagom i s manjim ekološkim standardima.

Slika 7.

PREMJEŠTANJE POGONA IZVAN EU DA OSTVARI UŠTEDE,
HRVATSKA U ODNOSU NA EU




Kao što vidimo iz slike 7. većina ispitanika u Hrvatskoj nema mišljenje o premještanju proizvodnih pogona. To je i razumljivo, zato što se Hrvatska bori da očuva ono malo proizvodnje što je ima i da ljudi ostanu zaposleni, a nije na tome stupnju da može investirati u automatizaciju.

Budući da je informacijsko komunikacijska tehnologija (ICT) već sada u široj upotrebi, a uskoro bi morala biti posvuda, testirali smo jednu tezu koja pripada toj grupi na hrvatskome uzorku. Pitanje je: kada će biti u široj upotrebi inteligentni samoučeći kontroleri? Evo što hrvatski stručnjaci misle:

Slika 8.


PROIZVODNJA KONTROLIRANA SAMOUČEĆIM INTELIGENTNIM KONTROLERIMA



Vidimo da 13% stručnjaka predviđa da će ICT tehnologija biti u Hrvatskoj u široj primjeni već prije godine 2010. Zatim slijedi 29% stručnjaka koji misle da će ta tehnologija biti rasprostranjena između godina 2010.-2015., a 38% stručnjaka smatra da će to u Hrvatskoj u većim razmjerima biti tek nakon godine 2015. Dakle, vidimo da će se u odnosu na sliku 5. ICT tehnologija koja će najranije zaživjeti u Europi, u Hrvatskoj prema prognozama stručnjaka uglavnom dogoditi nakon godine 2010.

Slika 9.


ZAOSTAJE LI HRVATSKA U ODNOSU NA EU U PRIMJENI INTELIGENTNIH KONTROLERA?



Inteligentni kontroleri naprave su kojima se na brz način mogu unijeti u računalo promjene (npr. promjena matrica kod različitih vrsta kabela, promjena kalupa u prehrambenoj industriji) da bi uslijedila brza izmjena za proizvodnju drugoga tipa proizvoda. Slika br. 9. pokazuje da u Hrvatskoj čak 35% ispitanika smatra da smo u toj tehnologiji prosječni i da ne zaostajemo, a 59% stručnjaka smatra da ipak zaostajemo u širokoj upotrebi inteligentnih kontrolera u proizvodnji. Time, dakle, možemo potvrditi našu postavljenu hipotezu da Hrvatska zaostaje za Europom.

Slika 10.

UTJECAJ INTELIGENTNIH KONTROLERA NA KONKURENTNOST




Inteligentni kontroleri time što smanjuju vrijeme zamjene alata, matrica i kalupa značajno smanjuju brzinu proizvodnje. Osim toga, uz pomoć inteligentnih kontrolera moguće je držati boju, sastojak ili slično u različitim posudama, a kontroler se programira da u određenome trenutku vuče smjesu iz drugoga spremnika. To se možda i ne čini velikom stvari, ali predstavlja značajnu uštedu u materijalu i čišćenju. Ako se koristi jednim spremnikom prije druge serije, spremnik se mora oprati (dakle, potrebno je sredstvo za čišćenje i dio materijala s tim čišćenjem odlazi u nepovrat). Stoga uopće nije iznenađujuće da hrvatski stručnjaci predviđaju kako se upotrebom inteligentnih kontrolera može povećati konkurentnost.

Glavni je razlog, po mišljenju hrvatskih stručnjaka, zbog kojeg se ovom tehnologijom ne koristi nedostatak investiranja u istraživanje i razvitak.

Slika 11.

PREPREKE ZA PRIMJENU INTELIGENTNIH KONTROLERA U PROIZVODNJI



Kao što vidimo na slici 11. glavnom preprekom 49% ispitanika smatra nedostatak ulaganja u istraživanje i razvitak, zatim slijedi ekonomska neizvedivost sa 28% (dakle nedostatak materijalnih sredstava za ulaganje u modernizaciju), a na trećem je mjestu tehnološka prepreka sa 23%. To je prilično veliki postotak, jer to možemo protumačiti kao da 23% stručnjaka smatra da su proizvodni procesi do te mjere zastarjeli da nadogradnja tih kontrolera uopće nije moguća.

Još ćemo pogledati kako Hrvatska stoji u upotrebi inteligentnih i nano materijala koji se smatraju najvećim izvorima konkurentske prednosti¹³: nažalost,


¹³ Ovu tvrdnju potkrepljujemo činjenicom da je Amerika vodeća sila koja najviše ulaže (vidjeti sliku 3). Osim toga, prema Russel i Taylor (2006.), *Operations Management*, Wiley, str. 18. Amerika je vodeća konkurentska sila. Dodatno to možemo potkrijepiti sa «Global Competitiveness Report 2005-2006» <http://www.weforum.org/site/homepublic.nsf/Content/Global+Competitiveness+Programme%5CGlobal+Competitiveness+Report>, iako je prema tom istraživanju Finska prva, a zatim slijedi Amerika.

većina hrvatskih stručnjaka na to nema nikakvog odgovora. Očito su inteligentni materijali daleka budućnost za Hrvatsku.

Ipak veseli činjenica da 3% hrvatskih stručnjaka misli da će upotreba tih materijala započeti prije godine 2010. (slika 12.). Nešto veći postotak (8%) stručnjaka smatra da će šira upotreba nastupiti u razdoblju od godine 2010. do 2015. Također 8% smatra da će šira upotreba biti u razdoblju od 2015. do 2020. godine. Ako bismo se vratili na sliku 5. vidjeli bismo da se procjene naših stručnjaka znatno ne razlikuju od procjena njihovih europskih kolega.


Slika 12.

VRIJEME ŠIROKE PRIMJENE INTELIGENTNIH MATERIJALA



Slika 13.

ZAOSTAJE LI HRVATSKA ZA EU U INTELIGENTNIM MATERIJALIMA




Većina stručnjaka iz Hrvatske (64%) nema mišljenje ni saznanja za usporedbu zaostaje li Hrvatska u tome pitanju za Europom. Razlog je vjerojatno činjenica da ispitani stručnjaci u svom svakodnevnom radu uopće ne dolaze u dodir s takvim materijalima. Čak 12% stručnjaka smatra da smo po korištenju inteligentnih materijala prosječni, a 20% stručnjaka misli da zaostajemo za Europom.

Slične rezultate dobili smo za upotrebu nano materijala:

Slika 14.

PROCJENA KADA ĆE NANO MATERIJALI BITI U ŠIROKOJ UPOTREBI



Opet većina ispitanika nema mišljenje o upotrebi nano materijala. Oni se za svoju djelatnost vjerojatno ne koriste i ne planiraju se koristiti tim materijalima, pa ne mogu ocijeniti kada bi ušli u širu upotrebu. Ipak 3% stručnjaka smatra da će ti materijali biti u upotrebi prije godine 2010. Zanimljivo je da 9% stručnjaka misli da će oni biti u upotrebi tek nakon godine 2020., ali nijedan stručnjak nije procijenio da ti materijali nikada neće biti u upotrebi u Hrvatskoj. Ako ponovno pogledamo sliku 5., vidimo da se ta prognoza ne razlikuje značajno od prognoze cjelokupne skupine stručnjaka.


Nije potrebno ići dalje u analizu pojedinih tvrdnji, jer je većina tih koncepata nova i za Europu, a pogotovo za Hrvatsku. No, ono što je zanimljivo jest činjenica da je svaka zemlja imala pravo postaviti pet teza specifičnih za svoju zemlju. Sada ćemo analizirati kako hrvatski stručnjaci gledaju na te probleme.

Hrvatske specifične tvrdnje:

Prva tvrdnja polazi od teze da bi kada bi država poticala industriju, to bio izvor konkurentne prednosti za Hrvatsku. Činjenica je da je u hrvatskome gospodarstvu stanje veoma loše i da se zapravo potiče uvoz. Tu tezu potkrepljujemo izvješćem hrvatskoga Nacionalnog vijeća za konkurentnost koje prikazuje udio uvoza u odnosu na BDP.

Slika 15.

IZVOZ I UVOZ U HRVATSKU




Izvor: http://www.vlada.hr/Download/2004/04/13/55_preporuka.pdf, str.18

Inicijative kao «kupujmo hrvatsko» dobre su, ali nisu dovoljne da se potakne gospodarstvo u cjelini. Pogledat ćemo samo glavne prepreke za realizaciju te tvrdnje.

Slika 16.

GLAVNE PREPREKE ZBOG KOJIH DRŽAVA
 NE POTIČE PROIZVODNJU



Vidimo da su glavni razlozi u zakonima (26%) – ponajprije se mislilo na regulirane postupke naplaćivanja za isporučenu robu; u ekonomskoj izvedivosti (31%) – pretpostavlja se da su stručnjaci pod time mislili da država jednostavno nema sredstava za subvencioniranje proizvodnje. Veoma visok postotak dobilo je mišljenje da nema dovoljno obrazovanih stručnjaka (14%). Ponovo se kao problemi javljaju nedovoljno investiranje u istraživanje i razvitak (10%) i tehnološka neizvedivost (10%), pritom se misli da same poticajne mjere ne bi bile dovoljne za modernizaciju proizvodnje, nego je potrebno veće financijsko ulaganje.

Druga je tvrdnja bila da je samo uz permanentno obrazovanje i uz primjenu novih tehnologija moguće biti konkurentan. Pogledajmo što hrvatski stručnjaci vide kao prepreke za realizaciju te tvrdnje:

Tablica 3.

PREPREKE GLOBALNOJ KONKURENCIJI

| Prepreke | Broj |
|--|------|
| Nedostatak obrazovanja/kvalifikacija | 38 |
| Ekonomska izvedivost (dugoročno neisplativo) | 21 |
| Manjak I&R | 18 |
| Socijalna prihvatljivost | 9 |
| Tehnološka izvedivost | 11 |
| Zakoni | 7 |

Glavni je motiv za postavljanje ove tvrdnje izvješće hrvatskoga Nacionalnog vijeća za konkurentnost. «Na istraživanje i razvoj izdvaja se 1,1 posto BDP-a, od čega su čak 2/3 ulaganja javnog sektora. Hrvatski poslovni sektor zapošljava samo 19% istraživača, dok taj postotak na razini Europske unije iznosi 56%. Kao primjer uspješnog razvojnog modela je nordijski model koji objedinjuje socijalno osjetljivo, izuzetno konkurentno, fleksibilno, efikasno i politički odgovorno društvo u kojem se za obrazovanje izdvaja do čak 8% BDP-a. Prosjek Europske unije je 5,1%»¹⁴

Možemo spomenuti i preporuku br. 6. Nacionalnog vijeća za konkurentnost, prema kojoj je potrebno povećati broj studenata tehničkih i prirodnih znanosti:

«Prijavljene godišnje potrebe za visokoobrazovanim osobama gotovo su 50% veće od broja nezaposlenih te razine obrazovanja, što upućuje na stalan manjak pojedinih profila stručnjaka. U Hrvatskoj se udjel diplomiranih studenata prirodnih i tehničkih znanosti u ukupnom broju diplomanata smanjuje, a to je upravo suprotno potrebama globalnog tržišta. Stoga je kratkoročni prioritet povećavati upisne kvote studija tih područja. Zbog sve veće potrebe za vještinama iz IT i e-businessa preporučuje se uključivanje tih sadržaja u sve obrazovne smjerove.»¹⁵

Drugi je po redu problem ekonomska izvedivost. To znači da poduzeća sama ne mogu izdvajati za permanentnu naobrazbu svoga kadra, zato što većinu dobiti reinvestiraju u tehnologiju da bi ostali konkurentni. Posljedica je toga da će se ljudski potencijali tih poduzeća obrazovati o vlastitome trošku, a to je opet privilegija samo bolje stojećih. Nacionalno vijeće za konkurentnost iznijelo je podatak:

«Hrvatska je još daleko od ispunjavanja jednog od ključnih prioriteta Lisabonske agende – izdvajanja 3 posto BDP-a za istraživanje i razvoj. Neprihvatljivo je da u Hrvatskoj samo 0,2 posto zaposlenih starijih od 35 godina sudjeluje u procesu učenja na radnom mjestu, dok taj postotak u zemljama Europske Unije dosiže 7%»¹⁶


¹⁴ <http://nvk.multilink.hr/jesteliznali.asp?ID=37>

¹⁵ http://nvk.multilink.hr/dokumenti/110___55%20preporuka%20za%20povećanje%20konkurentnosti%20Hrvatske.pdf, str. 26

¹⁶ <http://nvk.multilink.hr/jesteliznali.asp?ID=39> (17. siječnja 2006.)

Slika 17.

PREPREKE STALNOME OBRAZOVANJU I USVAJANJU SUVREMENE TEHNOLOGIJE




Ovo nije problem samo u Hrvatskoj, nego je problem i u Europi. Naime, jedna je od tvrdnji bila da je za konkurentnost bitno stalno učiti i institucionalizirati učenje u organizacijama, ali je glavna prepreka da bi se to ispunilo manjak dovoljno obrazovanog i stručnog kadra. Ono čega su Hrvati možda svjesniji od svojih kolega u Europi jest činjenica da to znanje nije besplatno.

Treći je problem, po našem mišljenju i osnovni, taj da se samo inovacijama može postići konkurentna prednost i da se samo tako mogu otvoriti dodatna radna mjesta. Pogledajmo gdje su tu glavne prepreke.

Slika 18.

PREPREKE ZA KREIRANJE INOVACIJA I TIME DODATNIH RADNIH MJESTA



Kao što vidimo glavne su prepreke nedostatak obrazovanoga kadra i nedovoljna ulaganja u istraživanje i razvitak. Da bi se stalno inoviralo, potreban je visokokvalificirani kadar - to smatra 30% stručnjaka. Drugi bitan čimbenik da bi se inoviralo jest potreba ulagati u istraživanje i razvitak, što smatra 27% stručnjaka. Na trećem je mjestu ekonomska izvedivost (19%), tj. jednostavno nedostatak sredstava za ulaganje. Prilično veliki postotak stručnjaka (15%) misli da im je postojeća tehnologija slabost koja sprečava inoviranje proizvoda, tj. potrebno je prvo uložiti u modernizaciju, a nakon toga dodatno uložiti u obrazovanje i istraživanja. Zanimljivo je da 5% stručnjaka vidi prepreku u zakonu. Pretpostavljamo da se radi o tome da stručnjaci smatraju da patentna prava nisu dobro zaštićena.

Zaključak:

Da bi se moglo konkurirati u današnjem globalnom, turbulentnom okruženju osobito je važno dobro se pripremiti. Za to su nam bitna predviđanja i prognoze. Delphi metoda jedan je od najjačih alata za prognoziranje budućnosti. Da su tvrdnje dobro pogođene proizlazi iz toga što su ispitanici na većinu tvrdnji odgovorili da su one relevantne za europsku proizvodnju. Tim stručnjaka koji je sastavljao teze bio je internacionalan, tj. uključivao je predstavnike iz Amerike i Japana, i to zato bi se izbjegla zatvorenost u samo europske probleme. Tih 130 teza poslane su svim zemljama članicama koje su organizirale nacionalne radionice na kojima su ispitivane jasnoća teza, njihova eventualna promjena ili izbacivanje. Rezultat je da je ostala 101 teza. Ukupan broj stručnjaka koji je odgovarao u prvome krugu Delphi istraživanja bio je 2993, a to je samo za sedam manje od ciljanoga uzorka.

Naše se istraživanje, sastojalo od tri dijela. Najprije smo predstavili agregirane rezultate na razini svih 22-iju zemalja sudionica, zatim smo po pojedinim pitanjima analizirali kako razmišljaju hrvatski stručnjaci, a na kraju smo ispitali rezultate za tri specifične hrvatske tvrdnje, iako bi one mogle vrijediti i općenito u Europi. Te specifične hrvatske tvrdnje proizašle su iz glavnih problema s kojima se susreću stručnjaci iz gospodarstva, dakle, to su konkretni problemi koje bi valjalo riješiti.

Rezultati su iznimno zanimljivi, i to kako oni općeniti na europskoj razini, tako i u usporedbi s odgovorima samo iz Hrvatske. Glavni problem koji muči Europu jest problem premještanja proizvodnje u područja s manjim troškovima radne snage i s nižim ekološkim standardima. Pitanje koje se je odnosilo na to jest tvrdnja S045 kojom se postavlja pitanje: bi li viša automatizacija umanjila efekte koji se dobivaju premještanjem u krajeve s nižim troškovima? Odgovor nije jednoznačan, jer, iako bi viša automatizacija zaista podigla konkurentnost europskoga gospodarstva, to bi negativno utjecalo na zaposlenost. Europa ima visoku stopu nezaposlenosti, a socijalno je osvještenija od npr., Amerike i Japana. To isto pitanje kod hrvatskih

je stručnjaka izazvalo indiferentnost, jer se u Hrvatskoj susrećemo s problemima sasvim drugačijima od onih u Europi. U Hrvatskoj je bitno održati proizvodnju, a uz iznimku maloga broja proizvodnih tvrtki, hrvatske tvrtke nemaju sredstava da uopće razmišljaju o premještanju svojih pogona.

Drugo veoma važno pitanje bilo je: kako povećati konkurentnost europskoga gospodarstva? Stručnjaci predviđaju da je ako se želi slijediti velike sile kao što su Amerika ili Japan, potrebno više ulagati u razvijanje i upotrebu inteligentnih, nano materijala, u automatizaciju i u robotiku. Tome predstoje određene prepreke. Na osnovi uzorka svih dvadeset dviju zemalja proizašlo je da su glavne prepreke ekonomska održivost i tehnološka provedivost, a tek je na trećem mjestu nedostatak ulaganja u istraživanje i razvitak. Mi mislimo da je glavni problem nedovoljno investiranje u istraživanje i razvitak, što potkrepljujemo pokretanjem «Lisabonske konvencije».¹⁷

Osobito je zanimljivo mišljenje kako se gdje investira. Konkretno, za svaku je tvrdnju bilo pitanje: tko najviše investira? Ponuđeni odgovori bili su Amerika, Japan, Kina i ostali. Rezultati pokazuju slijedeću raspodjelu:

Europa najviše investira u to da proizvodnja bude ekološka i da se u što većoj mjeri koriste recikliranim izvorima materijala. U Americi su najveće investicije u nano materijale i materijale s biološkim komponentama. Za razliku od Amerike i Europe, Japanci najviše investiraju u robotiku i u što veću automatizaciju. Čini se da Amerika ipak ima najjače investiranje u fundamentalne znanosti, što je šteta, jer njima većina kadra dolazi iz Europe, a to znači da Europa ima potencijal za fundamentalna istraživanja.

Još je jedna tvrdnja izazvala veliku pozornost stručnjaka, a to je - ako se mala poduzeća, svako specijalizirano za svoje područje, udruže, moguće je konkurirati na globalnoj razini. To je druga tvrdnja, po važnosti odmah nakon premještanja proizvodnje.

Naposljetku smo se željeli osvrnuti na teze koje muče hrvatsko gospodarstvo. To se ponajprije odnosi na ulogu države u zaštiti i pomoći hrvatskome poduzetništvu, na potrebu stalnoga obrazovanja i na primjenu novih tehnologija i važnost inovacija. Glavne prepreke za ostvarivanje ovih tvrdnji stručnjaci vide u zakonima, a još i nedostaje kvalificirani kadar. Smatramo da bi svakako bilo potrebno prihvatiti preporuku br. 6 Nacionalnog vijeća za konkurentnost, jer konkurentnost veoma ovisi o mogućnosti inovacija, a to se ne može postići bez vrhunskoga kadra.

Ovo je opis samo dijela rezultata prvoga kruga MANVIS Delphi istraživanja. U tijeku je drugi krug u kojem se ocjenjuju samo 22 tvrdnje na koje su dobijeni

¹⁷ <http://europa.eu.int/invest-in-research/>

nejednoznačni odgovori. Za ilustraciju problema govorimo o tvrdnji S045, u kojoj se tvrdi da se većom automatizacijom može spriječiti premještanje proizvodnje van Europe, a u tvrdnji S039 govori se da će proizvodnja ipak biti u bližoj budućnosti premještena. Omjer odgovora na ta pitanja je 50:50 za i protiv, pa se nadamo da će u drugome krugu problem premještanja proizvodnje biti razjašnjen.

Prema ovome istraživanju, ali i prema ocjeni Nacionalnog vijeća za konkurentnost, naša je hipoteza da hrvatska proizvodnja zaostaje za europskom potvrđena. Prognoze su stručnjaka da će materijali koji će biti u široj upotrebi do godine 2010. u Europi, u Hrvatsku doći znatno kasnije. Prognoze ovoga istraživanja mogu poslužiti poduzećima za dugoročno planiranje, ali i kao poticaj za unaprjeđivanje njihove proizvodnje.

LITERATURA

1. Armstrong, J. S. (1978): *Long-Range Forecasting: From Crystal Ball to Computer*, John Wiley, str. 68
2. Benson, P., Hill, A. and Hoffmann, T. (1982), "Manufacturing systems of the future – a Delphi study", *Production & Inventory Management*, Vol. 23 No. 3, str. 87-105. <http://www.nap.edu/openbook/0309061822/html/index.html>
3. Beretta, R. (1996), "A critical review of the Delphi technique", *Nurse Researcher*, Vol. 3 No. 4, str. 79-89.
4. Chase R. B., Aquilano N.J., Jacobs F.R., (2001), *Operations Management for Competitive Advantage 9e*, McGraw Hill, str.434
5. Chopra S., Meindl P., (2004), *Supply Chain Management: Strategy, Planning and Operations*, Prentice Hall, str. 171
6. Czinkota, Michael R., Ronkainen, Ilkka A. (2005). «A forecast of globalization, international business and trade: report from a Delphi study», *Journal of World Business*, (40), 2: 111-123
7. Dreher C., Armbruster H., Schirrmeister E., Jung-Erceg P., (2005), *Preliminary Results from the 1st Round of the ManVis Delphy Survey*, http://www.manufacturing-visions.org/ManVis_Report_2_Final.pdf
8. Fernández-Palomero Morales D. (2004), *Relocation under debate*, <http://www.eurofound.eu.int/2004/02/feature/es0402205f.html>
9. Ishikawa, A., Amagasa, M., Shiga, T., Tomizawa, G., Tatsuta, R. and Mieno, H. (1993), "The maxmin Delphi method and fuzzy Delphi method via fuzzy integration", *Fuzzy Sets and Systems*, Vol. 55 No. 3, pp. 241-53.
10. Kenneth Albert (ed.), (1983) *The Strategic Management Handbook*, New York: McGraw Hill, str. 2-32.

11. Loo R., (2002), "Delphi method: a powerful tool for strategic management", *An International Journal of Police Strategy & Management*, Vol 25. No. 4, str. 762
12. MacCarthy B.L., Atthirawong W., (2003), "Factors affecting location decisions in international operations – a Delphi study", *International Journal of Operations & Production Management*, Vol. 23, No. 1, str. 796
13. McKee, M., Priest, P., Ginzler, M. and Black, N. (1991), "How representative are members of expert panels?", *Quality Assurance in Health Care*, Vol. 3, str. 89-94.
14. Mintzberg H, Lampel J., Quinn J.B., Ghosal S., (2003), *The strategy process* 4e, Prentice Hall, str. 4
15. Mullen, P. M. (2003), "Delphi: myths and reality", *Journal of Health Organization and Management*, Vol. 17 No. 1, str. 37-52
16. National Academy of Sciences, (2004), http://books.nap.edu/execsumm_pdf/6314.pdf, <http://bob.nap.edu/readingroom/books/visionary/index.html>
17. Pun K.F., Chin K.S, White A. S., Gill R. (2004) Determinants of manufacturing strategy formulation: a longitudinal study in Hong Kong, *Technovation*, Vol. 24, str. 121–137
18. Reid, N. (1988), "The Delphi technique: its contribution to the evaluation of professional practice", in Ellis, R. (Ed.), *Professional Competence and Quality Assurance in the Caring Professions*, Chapman & Hall, London, str. 230-62.
19. Russel R.S., Taylor B.W., (2005), *Operations Management 5e*, Wiley
20. Sackman, H. (1975), "Summary evaluation of Delphi", *Policy Analysis*, Vol. 1 No. 4, str. 693-718.
21. Scheibe, M., Skutsch, M. and Schofer, J. (1975), "Experiments in Delphi methodology", u Linstone, H.A. and Turoff, M. (Eds), *The Delphi Method: Techniques and Applications*, Addison-Wesley Publishing Company, Reading, MA, str. 262-87
22. Shint T, (1998), "Using Delphi for a Long-Range Technology Forecasting, and Assessing Directions of Future R&D Activities, The Korean Exercise", *Technological Forecasting and Social Change* 58, 126 and 129
23. Tracey M., Vonderembse M.A., Lim J-S., (1998), "Manufacturing technology and strategy formulation: keys to enhancing competitiveness and improving performance", *Journal of Operations Management*, Vol. 17, str. 411
24. Tavana, M., Kennedy, D. and Joglekar, P. (1996), "A group decision support framework for consensus ranking of technical manager candidates", *Omega International of Management Science*, Vol. 24 No. 5, pp. 523-38
25. Turoff, M. (1970), "The design of a policy Delphi", *Technological Forecasting and Social Change*, Vol. 2 No. 2, pp. 149-71.

26. Walonick D. S., (2004), An Overview of Forecasting Methodology, <http://www.statpac.com/research-papers/forecasting.htm>
27. Waddell D., Sohal A.S. (1994), "Forecasting: The Key to Managerial Decision Making", *Management Decision*, Vol 32, No 1, str. 41-49
28. Wild, C., Torgersen, H. (2000), "Foresight in medicine: lessons from three European Delphi studies", *European Journal of Public Health*, Vol. 10 No. 2, str. 114-9 i Cantrill, J.A., Sibbald, B., Buetow, S. (1996), "The Delphi and nominal group techniques in health services research", *International Journal of Pharmacy Practice*, Vol. 4 No. 2, str. 67-74
29. Wit B., Meyer R., (1998), *Strategy: Process, Content and Context*, Thompson, str. 220

MANUFACTURING IN EUROPE AND CROATIA TILL 2020: THE FORECASTS OF MANVIS DELPHI RESEARCH

Summary

Good forecasting is extremely important for strategic and tactical decision making. Forecasting enables companies, individuals or whole nations to prepare themselves for future events. That is why the European Commission started the project Manufacturing Visions – MANVIS – so that we can investigate the future of manufacturing in Europe.

MANVIS is designed as a holistic research of relevant concepts – from manufacturing technology to organisational concepts. The research is divided into 10 main topics. Primary focus is put on time span of realisation and widespread use of certain concept and the question: does Europe lag behind world forces as America and Japan. 22 countries were involved in the research. As in many long term forecasting researches (time span is 20 years), Delphi method is used.

The results are very interesting for the whole Europe and we compared them to Croatian answers. The main problem in Europe is the question of relocation to areas with lower labour costs and lower environmental standards. The other important question is how to increase Europe's competitiveness. Now we see that it is necessary to invest more into research and development of intelligent and nano materials. Experts say that potential barriers are economic viability, technological feasibility, and lack of R&D funding.

Finally we would like to address questions which bother Croatian companies. Results show that Croatian government should take a more active role in protecting local manufacturing. Also is needed to invest in permanent education, the necessity of using new technologies and more innovations. To solve these problems, the identified barriers are the inefficiency of public law and lack of highly qualified human resources. We believe that government incentives to local production would keep these invaluable human resources in Croatia. The source of competitive advantage greatly depends on possibility of innovation and that cannot be achieved without top specialists.

Key words: Forecasting, European production, Delphi method, manufacturing visions