

SVEUČILIŠTE U RIJECI
FAKULTET ZA MENADŽMENT U TURIZMU I
UGOSTITELJSTVU OPATIJA

Vanja Vitezić

**INOVACIJSKI MENADŽMENT I
EFIKASNOST PODUZEĆA S NISKOM I
SREDNJE NISKOM TEHNOLOŠKOM
RAZINOM**

DOKTORSKA DISERTACIJA

RIJEKA, 2017.

SVEUČILIŠTE U RIJECI
FAKULTET ZA MENADŽMENT U TURIZMU I
UGOSTITELJSTVU OPATIJA

Vanja Vitezić

**INOVACIJSKI MENADŽMENT I
EFIKASNOST PODUZEĆA S NISKOM I
SREDNJE NISKOM TEHNOLOŠKOM
RAZINOM**

DOKTORSKA DISERTACIJA

Mentor: prof. dr. sc. Borut Likar
Komentor: izv. prof. dr. sc. Marko Perić

RIJEKA, 2017.

UNIVERSITY OF RIJEKA
FACULTY OF TOURISM AND HOSPITALITY
MANAGEMENT OPATIJA

Vanja Vitezić

**INNOVATION MANAGEMENT AND
EFFICIENCY OF LOW- AND MEDIUM-
LOW-TECH ENTERPRISES**

DOCTORAL THESIS

RIJEKA, 2017.

Mentor: prof. dr. sc. Borut Likar

Doktorska disertacija obranjena je dana 15. prosinca 2017. godine, na Fakultetu za menadžment u turizmu i ugostiteljstvu Opatija, pred povjerenstvom u sastavu:

1. prof. dr. sc. Želimir Dulčić, predsjednik
2. prof. dr. sc. Borut Likar, mentor i član
3. izv. prof. dr. sc. Marko Perić, komentor i član
4. izv. prof. dr. sc. Ines Milohnić, članica
5. doc. dr. sc. Goran Karanović. Član

Posvećeno mom tati.

Hvala ti na svemu,

bio si i ostat ćeš moj veliki uzor.

SAŽETAK

Inovativnost je jedna od ključnih odrednica 21. stoljeća, pa je stoga i upravljanje inovacijama aktualna tema u znanstvenoj literaturi iz područja menadžmenta. Razlog tome jest opstanak poduzeća u ekonomskim uvjetima globalizacije s orijentacijom na održivost. Inoviranje zahtijeva odgovorno upravljanje usmjereno ciljevima, procesni pristup organizaciji, izvršavanje, kontrolu i mjerenje postignutih rezultata koji vode k uspješnoj inovaciji. No sve inovacije nisu uspješne jer ovise o vrsti inovacije i načinu upravljanja procesom inovacija, tj. transformacije ideje u inovaciju. Predmet istraživanja srednje su velika i velika poduzeća s niskom i srednje niskom razinom tehnološke razvijenosti u Republici Hrvatskoj (HR NTP) koja su najviše zastupljena u prerađivačkoj industriji. Cilj istraživanja jest razvoj modela za cjelovitije i uspješnije upravljanje inovacijama s mogućnošću primjene i na uslužna poduzeća. Da bi se oblikovao inovativan model, empirijski je utvrđena pozitivna veza između visine i strukture ulaganja u inovacije i izlaznih pokazatelja inovacija u 996 HR NTP. Jednako tako, istražena je i utvrđena međusobna povezanost pokazatelja inovacijskih ulaganja, pokazatelja upravljanja inovacijskim procesom i inovacijskih rezultata 967 njemačkih poduzeća s niskom i srednje niskom razinom tehnološke razvijenosti. Statističkim testovima potvrđena je povezanost između inovacijskih rezultata i gospodarske efikasnosti hrvatskih i njemačkih poduzeća. Faktorskom analizom izlučeno je šest inovacijskih sposobnosti te je potvrđeno da među skupinama poduzeća postoji statistički značajna razlika u organizacijskoj, marketinškoj, proizvodnoj, istraživačko-razvojnoj, informacijskoj i koordinacijskoj sposobnosti te sposobnosti strateškog upravljanja. Znanstveno je dokazano da HR NTP inovacijom procesa postižu uštede, kvalitetom povećavaju prihod, a marketinškim i organizacijskim inovacijama te inovacijom poslovnog modela pozitivno utječu na razinu inovacija proizvoda. Oblikovanjem modela za cjelovitije i uspješnije upravljanje inovacijama pridonosi se menadžerskoj praksi na različitim razinama upravljanja.

Ključne riječi: inovacije, inovacijski menadžment, niska i srednje niska tehnološka razina, inovacijske sposobnosti, prerađivačka industrija, hotelijerstvo.

SUMMARY

In today's economy, pervaded by constant globalization pressures and rapid technological advancement, innovation is considered to be the main precondition for sustainable growth and enterprise development. Innovation provides firms with growth that is more competitive, faster, better and smarter than that of their competitors, and gives them the ability to influence the industry in which they operate. Understanding the source of successful innovation has become one of the major challenges for researchers around the world. Over the years the definitions given by various authors have made the concept of innovation clearer. While a unique and commonly accepted definition of innovation does not exist, most agree that innovation implies the development and application of something new or substantially altered, whether it is a product or service, a new organizational method, a business practice or a new marketing method. Successful innovation is the creation and implementation of new processes, products, services or delivery methods that result in significant improvements in achieving the desired result, efficiency, effectiveness or quality. However, it is not the authors and owners of a new idea, product, process or organizational or marketing innovation but rather the customers who decide which of the same will be successful innovations.

Innovation management has become one of the most popular topics in the scientific literature in the field of management, especially in the last ten years. The reason for this lies in the need to ensure the survival of sustainability-focused companies in economic conditions of globalization; this applies to both for-profit companies that need to be competitive, as well as to non-profit companies that need to improve their services. Innovation calls for knowledge about innovation management, about how to actively and conscientiously organize, control and execute activities that lead to innovation. However, not all innovations are successful, as success depends on the type of innovation and the way the innovation process is managed, that is, how an idea is transformed into an innovation. Therefore, there are various innovation models, mainly related to products and processes, but also to services, given their importance in today's economy.

Innovation capacity is the ability of any organization to undertake activities to create new ideas that will enable development and long-term survival; it is the potential for generating innovation results. For instance, interlinking multiple dimensions of technological innovation capabilities

has a positive effect on the results of technological innovations and thus on business results. Input innovation factors and process management are directly influenced by management, while output factors are only partially controlled. It is therefore important to determine key input, process and output innovation factors. It was found that in addition to investment in innovation, innovation capabilities and innovation management also have a great impact on innovation performance. Therefore, the focus of this research is on defining those process innovation factors. The key question is how to encourage companies to boost innovation activity, that is, how to increase investment in research and development (R&D) and build innovation capacities and capabilities. The core idea of R&D activities and innovativeness in augmenting a firm's competitive capabilities and boosting the economy as a whole, that is in line with the goals of the Europe 2020 Growth Strategy. Growth of R&D investment (3% of GDP) will not be reachable if firms do not generate absorption capacities and an adequate innovation climate. If competitive capability is not increased through such R&D activities, any additional investment in R&D will be futile. If the state follows in the same footsteps and fails to take decisive action, the negative effects of R&D investment and drawing from EU funds could be far-reaching.

The subject of research is medium-sized and large firms in the Republic of Croatia, with low and medium-low levels of technological intensity, mostly present in the manufacturing industry. The manufacturing industry is the sector of the economy with one of the biggest shares in the structure of gross domestic product and the total employment of the Republic of Croatia, and the absolute largest share in total exports. It is considered appropriate to explore the possibilities of improving the innovation capabilities of firms in the manufacturing industry, which could, in turn, enhance the overall economic potential of Croatia by building innovation capacity.

A low level of technological development and less knowledge-intensive activities are found in the less knowledge-intensive services (LKIS), which also require a modern approach to managing innovation. Service innovation has a multidimensional character, because it involves distributing various types of product and service samples, interacting with guests, improving the organization of service delivery, introducing new technological options, or completely changing the business model. Although the hotel industry is identified as the most innovative industry within the tourism sector, it is also a part of the less knowledge-intensive service industry, and

because of its specific features (a combination of various service activities) it is very complex and requires the division of components and individual observation.

The goals and purpose of this doctoral dissertation are set based on the previously defined problems and subject of research. The purpose of the research is to explore the possibility of introducing holistic and successful innovation management in Croatian firms that have a low and medium-low level of technological intensity, based on the proposed transition model from a non-innovative to an innovative leading firm.

The scientific contribution of this dissertation is presented in a developed model of innovation management based on a holistic approach to the management of innovation factors. In order to design a more comprehensive and more successful innovative model applicable to the service sector, the theoretical elaboration of the concepts of innovation management (i.e. exploring types of innovation, innovation processes by phases, the use of management tools and relevant factors that impact the innovation capabilities of the firm) was followed by the empirical research of theoretical assumptions, conducted on 996 Croatian firms with low and medium-low levels of technological intensity (HR NTP). A positive correlation was established between the level and structure of investment in innovation and the output indicators of innovation. Equally, a positive link was determined between the innovation investment indicators, the indicators of innovation process management and the innovation performance of 967 German firms with low and medium-low levels of technological intensity (DE NTP). Furthermore, statistical tests confirmed the positive relationship between the innovation performance and the economic efficiency of Croatian and German NTP. By comparing results with German firms, knowledge transfer to Croatian companies was explored and realized. In the third phase of the research, exploratory factor analysis extracted six factors, i.e. innovation capabilities, for the entire sample. Further results indicated statistically significant differences regarding organizational, marketing, manufacturing, R&D, information and coordination and strategic management capability between innovation leaders and non-innovative HR NTP. Furthermore, through the innovation process, Croatian firms with low and medium-low technological intensity save on average, increase quality by increasing revenue, and positively affect the level of product innovation. Also, results have shown that marketing innovations, organizational innovations and the business model innovation of HR NTP have a positive impact on the level

of product innovation. Finally, data obtained from semi-structured interviews with hotel managers suggest that it is possible to successfully manage innovations in the hotel industry by retaining input innovation factors from the proposed model, by reformulating and modifying individual process factors, i.e. innovation capabilities, and by harmonizing individual output innovation factors.

This study contributes to managerial practice at different levels. The surveys and interviews conducted are very important for qualitative and quantitative research as they provide the practical confirmation of managers in the context of opportunities and, above all, their readiness to apply innovative models. The literature review for each segment of the proposed model confirms a positive impact on firm performance. In conclusion, innovation either increases value for the customer of the product (or service) or reduces costs, thus creating a competitive advantage for the enterprise. It is important to realize that innovation needs time and decision-makers should not rush to conclusions and over-emphasize key business indicators. Innovation is essentially a social process that is not just about invention but also about persuading people to do something new. Entrepreneurs who innovate persistently and develop routines and innovation capabilities among their departments and employees enhance their likelihood of success.

Key words: innovation, innovation management, low- and medium-low-tech enterprises, innovation capabilities, manufacturing industry, hotel industry.

Sadržaj

| | |
|---|-----------|
| SAŽETAK | I |
| SUMMARY | II |
| 1. UVOD | 1 |
| 1.1. Problem, predmet istraživanja | 1 |
| 1.2. Svrha i ciljevi istraživanja | 5 |
| 1.3. Znanstvena hipoteza i pomoćne hipoteze | 6 |
| 1.4. Znanstvene metode | 8 |
| 1.5. Doprinos znanosti | 14 |
| 1.6. Struktura rada | 15 |
| 2. TEORIJSKE OSNOVE INOVACIJSKOG MENADŽMENTA U OKRUŽENJU ODRŽIVOG RAZVOJA | 18 |
| 2.1. Pojmovno određenje i značaj suvremenog inovacijskog menadžmenta | 18 |
| 2.2. Koncept inovacija u okruženju održivog razvoja | 21 |
| 2.3. Teorijska ishodišta o vrstama inovacija i inovacijskim procesima | 23 |
| 2.3.1. <i>Različiti pristupi inovacijama</i> | 24 |
| 2.3.2. <i>Istraživanje i razvoj (R&D)</i> | 30 |
| 2.3.3. <i>Karakteristike pojedinih modela inovacijskih procesa</i> | 32 |
| 2.4. Analiza inovacijskih procesa | 35 |
| 2.4.1. <i>Faze inovacijskih procesa</i> | 37 |
| 2.4.2. <i>Mjerenje inovacijskih procesa</i> | 41 |
| 2.5. Holistički pristup poznavanju utjecajnih čimbenika i njihova međusobna povezanost pri mjerenju rezultata inovacijskih procesa | 47 |
| 3. ANALIZA INOVACIJSKIH SPOSOBNOSTI PODUZEĆA | 57 |
| 3.1. Apsorpcijski kapacitet | 58 |
| 3.2. Organizacijski kapacitet kao ključna determinanta razvijenosti | 60 |
| 3.3. Kapacitet strateškog planiranja i kontrole | 65 |
| 3.4. Proizvodni kapacitet | 70 |

| | |
|--|------------|
| 3.5. Informacijski i marketinški kapacitet | 71 |
| 3.6. Istraživačko-razvojni (R&D) kapacitet | 72 |
| 4. EMPIRIJSKO ISTRAŽIVANJE INOVACIJA KOD PODUZEĆA S NISKOM I SREDNJE NISKOM TEHNOLOŠKOM RAZINOM (NTP) | 75 |
| 4.1. Teorijska ishodišta za empirijsko istraživanje | 75 |
| 4.2. Poduzeća s niskom razinom inovativnosti – prerađivačka HR NTP..... | 80 |
| 4.3. Faza 1 – Analiza i ocjena hrvatskih poduzeća s niskom i srednje niskom tehnološkom razinom (HR NTP) (H1 do H4) | 88 |
| 4.4. Faza 2 – Analiza i ocjena njemačkih poduzeća s niskom i srednje niskom tehnološkom razinom (DE NTP) (H5 do H7) | 102 |
| 4.5. Faza 3 – Istraživanje na primarnim podacima hrvatskih poduzeća s niskom i srednje niskom tehnološkom razinom (HR NTP 2015) (H8 do H13) | 130 |
| 4.5.1. Ulazni inovacijski čimbenici HR PNT 2015 | 136 |
| 4.5.2. Procesni čimbenici inovacijske aktivnosti HR NTP 2015 | 150 |
| 4.5.3. Izlazni inovacijski čimbenici HR NTP 2015 | 176 |
| 4.5.4. Financijska efikasnost HR PNT 2015..... | 190 |
| 4.5.5. Model za prijelaz iz neinovativnog u inovativno vodeće poduzeće | 196 |
| 4.6. Inovacije u hotelijerstvu (H14)..... | 201 |
| 5. ZAKLJUČAK..... | 207 |
| LITERATURA..... | 215 |
| POPIS TABLICA | 248 |
| POPIS SLIKA..... | 251 |
| POPIS GRAFIKONA..... | 252 |

1. UVOD

1.1. Problem, predmet istraživanja

U današnjoj ekonomiji, prožetoj konstantnim globalizacijskim pritiscima i brzim napretkom tehnologije, inovacija se smatra glavnim preduvjetom održivog rasta i razvoja poduzeća. Inovacija pruža poduzećima konkurentnost, brži, bolji i pametniji rast u odnosu na svoje konkurente s mogućnošću utjecanja na smjer kojim se kreće industrija unutar koje posluju (Davila *et al.*, 2006). Razumijevanje izvora uspješne inovacije postalo je jedan od glavnih izazova za istraživače diljem svijeta. Tijekom godina definicije raznih autora pojašnjavale su pojam inovacija. Iako jedinstvena i uobičajeno prihvaćena definicija inovacija ne postoji, većina se slaže da inovacija podrazumijeva razvoj i primjenu nečeg novog ili bitno izmijenjenog, bio to proizvod ili usluga, nova organizacijska metoda, poslovna praksa ili nova marketinška metoda. Uspješna inovacija jest kreacija i implementacija novih procesa, proizvoda, usluga ili načina isporuke koji rezultiraju značajnim poboljšanjima u ostvarivanju željenog rezultata, efikasnosti, efektivnosti ili kvalitete (Albury, 2005), ali nije na autorima i vlasnicima nove ideje, proizvoda, procesa, organizacijske ili marketinške inovacije da odlučuju koja je od njih uspješna inovacija, već je odluka na kupcima (Mulej, 2005).

Definiranje inovativnog ponašanja poduzeća u literaturi ostalo je relativno neuvjerljivo i nedosljedno (Cho, Pucik, 2005). Međutim, važno je za spomenuti da iskustvo u inoviranju postaje jedan od najvažnijih pokretača. Pretpostavka je da poduzeća kroz inovativne procese uče i dalje se razvijaju (Carayannis *et al.*, 2006) te se koriste tim temeljem kako bi ispitala varijacije u inovativnosti poduzeća. Inovativnost se određuje nizom ključnih pokazatelja na ulaznoj, procesnoj i izlaznoj strani inovacija. Shvaćanje činjenice da inovacija nije određena faza u životnom vijeku poduzeća, već neprekidan proces trebalo bi pomoći u prepoznavanju pokretača i prepreka u inoviranju te olakšati upravljanje inovacijama u poduzeću (Carayannis, Provance, 2008). Prema istraživanju Peters i Rammera (2013), oko 90 % inovacijski aktivnih njemačkih prerađivačkih poduzeća u godini t ostaje inovativno i u sljedećim razdobljima, dok

uslužna poduzeća također prikazuju pozitivan trend u inovacijskoj aktivnosti, iako u nešto manjem postotku (79 %).

Inoviranje zahtijeva poznavanje načina upravljanja, tj. aktivnu i savjesnu organizaciju, kontrolu i izvršavanje aktivnosti koje vode k inovaciji (Hansen, Birkinshaw, 2007; Jacobs, Snijders, 2008). Sve invencije nisu uspješne jer ovise i o vrsti i o načinu upravljanja procesom inovacija, tj. transformacije ideje u inovaciju, pa stoga postoje i razni modeli inoviranja (Eveleens, 2010) koji se uglavnom odnose na proizvode i procese, ali i na usluge s obzirom na njihovu važnost u današnjoj ekonomiji (Tidd, Bessant, 2005; Jacobs, Snijders, 2008). Da bi inovativni proizvod ili proces uspio na tržištu, potrebni su pomaci u temeljnom poslovnom modelu. Mnoge inkrementalne ili čak radikalne inovacije procesa ili proizvoda nisu polučile očekivani rezultat u skladu s njihovim potencijalom jer su se kretale unutar ograničenja postojećeg ili tradicionalnog poslovnog modela.

Inovacijski kapacitet jest sposobnost bilo kojeg oblika organizacije da poduzima aktivnosti u cilju stvaranja novih ideja koje će omogućiti razvoj i dugoročni opstanak, odnosno to je potencijalna sposobnost generiranja inovacijskih rezultata (Neely *et al.*, 2001). Samo su poduzeća s kapacitetom za inoviranje sposobna odgovarati na stalne promjene te istraživati nove prilike na tržištu (Brown, Eisenhard, 1995). Drugim riječima, poduzeća s višim stupnjem inovativnosti bit će uspješnija u odgovoru na promjenjivu okolinu, ali će biti i uspješna u razvijanju novih kapaciteta/sposobnosti za postizanje boljih poslovnih rezultata (Llorens-Montes *et al.*, 2004). Prema Tiddu i Bessantu (2009), u nedostatku inovacijskih sposobnosti, poduzeća iskazuju slabost pri upravljanju inovacijskim procesom, što može rezultirati mnogim zastojima i promašajima u samoj inovaciji. Dok su akademska istraživanja tehnoloških sposobnosti poduzeća dovela do boljeg razumijevanja samog procesa tehničke promjene, i dalje ne postoji konsenzus o konačnoj definiciji inovacijskih sposobnosti. Tri su ključne inovativne sposobnosti koje to omogućavaju: znanje, stav prema novim idejama i kreativnost. Međusobna povezanost više dimenzija tehnoloških inovativnih sposobnosti pozitivno utječe na rezultate tehnoloških inovacija (Yam *et al.*, 2010), a time i na rezultate poslovanja. Jačanje jedne inovativne sposobnosti simultano će djelovati na druge, npr. sposobnost učenja utjecat će na istraživanje i razvoj (*Research and Development*, u daljnjem tekstu R&D), alokaciju resursa,

proizvodnju, marketing, organizaciju i drugo, što će se odraziti na bolje rezultate (novi proizvodi, rast prodaje, profitabilnost). Ulazni inovacijski čimbenici i upravljanje procesima pod izravnim su utjecajem menadžmenta, dok se izlazni čimbenici mogu samo djelomično kontrolirati. Stoga je važno odrediti ključne ulazne i izlazne inovacijske čimbenike (Likar *et al.*, 2012). Utvrđeno je da, uz troškove za inovacije, inovacijske sposobnosti i upravljanje, tj. procesni inovacijski čimbenici, imaju velik utjecaj na inovacijske rezultate stoga je fokus ovog istraživanja upravo na njihovu definiranju.

Postavlja se pitanje kako ohrabriti poduzeća da pojačaju inovacijsku aktivnost, odnosno kako da povećaju ulaganja u istraživanje i razvoj te osnaže inovacijske kapacitete. Treba li prihvatiti paradigmu otvorenog inoviranja (*open innovation*), koja predstavlja antitezu tradicionalnom, vertikalnom i integracijskom modelu inovacija u kojem unutarnje aktivnosti istraživanja i razvoja mogu dovesti do interno razvijenih proizvoda koje tvrtka tada komercijalizira. Nasuprot tome, otvorena inovacija pretpostavlja da se poduzeća mogu i trebaju koristiti idejama iz vanjskog svijeta kao i unutarnjim idejama, što je prednost u unapređenju vlastite tehnologije (Chesbrough *et al.*, 2006). Suštinska misao R&D aktivnosti i inovativnosti u funkciji povećanja konkurentskog kapaciteta poduzeća te samim time i ekonomije u skladu s ciljevima Europske strategije rasta Europa 2020. za povećanjem ulaganja u R&D (3 % BDP-a) neće se moći ostvariti ako poduzeća ne stvore apsorpcijski kapacitet i odgovarajuću inovacijsku klimu. Ako se kroz takve R&D aktivnosti ne poveća konkurentski kapacitet, svako dodatno ulaganje u R&D bit će uzaludno. Ako država krene istim putem i ne postupi promišljeno, negativni efekti ulaganja u R&D, ali i povlačenje sredstva iz fondova EU-a mogli bi biti dalekosežni (Prašnikar, 2006).

Uobičajeno, kada se naglašava “društvo znanja”, budući rast, zaposlenost, misli se na IT tehnologiju te se samim time i područje više istražuje, a zapostavljaju se razvojni potencijali ostalih industrija. U prerađivačkoj se industriji većina sadašnjih inovacijskih i tehnoloških politika temelji na neoklasičnim modelima inovacijskih istraživanja čiji je cilj još uvijek povećati industrijsku aktivnost istraživanja i razvoja u pojedinim odabranim područjima visoke tehnologije. Međutim, budući da se malo zna o složenom međudjelovanju R&D intenzivnih i R&D neintenzivnih prerađivačkih sektora i individualnim inovacijskim strategijama R&D neintenzivnih poduzeća u kreiranju novih inovacijskih i tehnoloških politika, postoji veliki rizik

od zanemarivanja drugih konkurentnih inovacijskih potencijala osim R&D-ja. Umjesto naglašavanja specifičnih niša R&D-ja kao najboljeg načina generiranja inovacija nove inovacijske i tehnološke politike, trebalo bi više uvažavati inovacijske strategije R&D neintenzivnih poduzeća kako bi se u budućnosti povećali inovacijski kapaciteti poduzeća te gospodarstva u cjelini (Som, Kirner, 2014). Posebno se to odnosi na prerađivačka poduzeća sa srednje niskom i niskom tehnološkom razinom razvijenosti (u daljnjem tekstu NTP) koja prema R&D pokazatelju snage igraju važnu ulogu u zapošljavanju (oko 60 % zaposlenih u EU-u). Iako je tendencija smanjenja NTP industrije (u ukupnoj prerađivačkoj industriji) prisutna još od 80-ih godina prošlog stoljeća te iako je zapažen i manji udio u dodanoj vrijednosti (Hirsch-Kreinsen, 2008), važnost ove industrije vidljiva je iz niza empirijskih rezultata koji naglašavaju inovacijske sposobnosti sektora niske tehnološke razine u zemljama s visokom tehnološkom razinom (Palmberg, 2001, Tunzelmann, Acha, 2005).

Predmet istraživanja jesu srednje velika i velika poduzeća s niskom i srednje niskom razinom tehnološke razvijenosti u Republici Hrvatskoj koja su najviše zastupljena u prerađivačkoj industriji. Prerađivačka industrija jest sektor gospodarstva s najvećim udjelom u strukturi bruto domaćeg proizvoda (BDP-a) i ukupnoj zaposlenosti Republike Hrvatske (cca 30 %) te s apsolutno najvećim udjelom u ukupnom izvozu. U ukupnoj vrijednosti prodaje industrijskih proizvoda u 2015. godini prerađivačka industrija sudjeluje s 83,5 % (Državni zavod za statistiku, www.dzs.hr, 22. 6. 2017.). Industrija je u 2015. godini ostvarila izvoz od 10,9 milijardi eura, što je 94,5 % ukupnog izvoza. Izvozna orijentiranost najsnažnija je u tradicionalnim granama prerađivačke industrije: metaloprerađivačka industrija sudjeluje s 24,9 %, kemija, proizvodnja kemikalija i kemijskih proizvoda, proizvodnja plastike i gume te farmaceutska industrija s 13,7 %, proizvodnja računala, električnih proizvoda i električne opreme s 9,5 %, proizvodnja prehrambenih proizvoda s 8,1 %, proizvodnja naftnih derivata sa 6,8 % te drvna industrija s 4,9 % (Hrvatska gospodarska komora, www.hgk.hr, 13. 5. 2017.). U skladu s navedenim, smatra se primjerenim istražiti mogućnosti unapređenja inovacijskih sposobnosti poduzeća u prerađivačkoj industriji koja bi jačanjem inovacijskog kapaciteta mogla osnažiti ukupni gospodarski potencijal Hrvatske.

Djelatnosti niske razine tehnološke razvijenosti, tj. znanjem manje intenzivne djelatnosti, nalaze se i u sektoru usluga (*less knowledge-intensive services* – LKIS) koje također zahtijevaju suvremeni pristup upravljanju inovacijama. Inovacije u uslugama ili inovacije u uslužnim djelatnostima imaju multidimenzionalan karakter jer se radi o distribuciji raznih vrsta uzoraka proizvoda i usluga, interakciji s gostom, poboljšanju organizacije pružanja usluge, uvođenju novih tehnoloških opcija, uglavnom IT, ili kompletnoj promjeni poslovnog modela (Den Hertog, 2010). Iako je hotelijerstvo identificirano kao najinovativnija industrija unutar sektora turizma, ono također spada u znanjem manje intenzivnu uslužnu djelatnost, a zbog svoje je specifičnosti (kombinacija različitih uslužnih aktivnosti) vrlo složeno i zahtijeva razdiobu na komponente i pojedinačno promatranje.

1.2. Svrha i ciljevi istraživanja

Iz prethodno definiranih problema i predmeta istraživanja postavljaju se ciljevi i svrha ove doktorske disertacije.

Svrha istraživanja: istražiti mogućnost cjelovitog i uspješnog upravljanja inovacijama u hrvatskim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti na temelju predloženog modela prijelaza iz neinovativnog u inovativno vodeće poduzeće.

Ciljevi su istraživanja sljedeći:

1. teorijski razraditi koncept upravljanja inovacijama, tj. istražiti vrste inovacija, inovacijske procese po fazama, primjenu menadžerskih alata i relevantne faktore koji utječu na inovacijski kapacitet poduzeća
2. utvrditi povezanost između visine i strukture ulaganja u inovacije i rezultata inovacija u hrvatskim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti (u daljnjem tekstu HR NTP)
3. utvrditi povezanost između inovacijskih rezultata i gospodarske efikasnosti hrvatskih poduzeća s niskom i srednje niskom razinom tehnološke razvijenosti

4. istražiti međusobnu povezanost pokazatelja inovacijskih ulaganja, pokazatelja upravljanja inovacijskim procesom i inovacijskih rezultata njemačkih poduzeća s niskom i srednje niskom razinom tehnološke razvijenosti (u daljnjem tekstu DE NTP)
5. usporediti rezultate s njemačkim poduzećima i istražiti je li moguć prijenos znanja na hrvatska poduzeća
6. oblikovati model za cjelovitije i uspješnije upravljanje inovacijama s mogućnošću primjene i na uslužna poduzeća.

1.3. Znanstvena hipoteza i pomoćne hipoteze

U skladu s definiranim znanstvenim problemom i predmetom istraživanja, postavlja se temeljna znanstvena hipoteza (H_0):

Znanstveno utemeljenim spoznajama o upravljanju inovacijama, karakteristikama inovacijskog kapaciteta hrvatskih poduzeća, značajkama hrvatskih poduzeća niske i srednje niske tehnološke razine i istraženim inovacijskim čimbenicima njemačkih poduzeća s niskom i srednje niskom tehnološkom razinom moguće je razviti model kojim će se uspješno upravljati inovacijama u hrvatskim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti.

Sljedeće pomoćne hipoteze podupiru temeljnu hipotezu:

H1: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP.

H2: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP.

H3: Ne postoji statistički značajna razlika u efikasnosti inovacijskog procesa inovacijsko vodećih HR NTP u odnosu na inovacijske sljedbenike i neinovativna HR NTP.

H4: Ne postoji statistička razlika u financijski izraženoj efikasnosti inovacijsko vodećih HR NTP u odnosu na inovacijske sljedbenike i neinovativna HR NTP.

H5: Na inovacijske rezultate DE NTP osim ulaznih inovacijskih čimbenika (visina i struktura ulaganja u inovacije) ne utječu i procesni inovacijski čimbenici (organizacija i upravljanje inovacijskim procesom).

H5a: Ne postoji statistički značajna razlika u efikasnosti inovacijskog procesa inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP.

H5b: Ne postoji statistički značajna razlika u visini i strukturi inovacijskih ulaganja inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP.

H5c: Ne postoji statistički značajna razlika između DE NTP u postotku zaposlenika uključenih na poslove R&D-ja.

H5d: Ne postoji statistički značajna razlika u inovacijskim sposobnostima inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP.

H5e: Ne postoji statistički značajna razlika u prosječnim uštedama troškova inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP.

H5f: Ne postoji statistički značajna razlika u poboljšanjima u kvaliteti inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP.

H6: Ulazni inovacijski čimbenici DE NTP statistički značajno ne utječu na procesne čimbenike DE NTP.

H7: Ne postoji statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih DE NTP u odnosu na inovacijske sljedbenike i neinovativna DE NTP.

H8: Ne postoji statistički značajna razlika u ulaznim inovacijskim čimbenicima unutar skupina HR NTP 2015.

H8a: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP 2015.

H8b: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP 2015.

H8c: Ne postoji statistički značajna razlika između HR NTP 2015 u postotku zaposlenika uključenih na poslove R&D-ja.

H9: Ne postoji statistički značajna razlika u procesnim inovacijskim čimbenicima (inovacijskim sposobnostima) inovacijsko vodećih poduzeća u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015.

H10: Inovacijom procesa HR NTP 2015 prosječno štede, povećavaju kvalitetu i pozitivno utječu na razinu inovacija proizvoda.

H10a: Ne postoji statistički značajna razlika u prosječnim uštedama troškova inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015.

H10b: Ne postoji statistički značajna razlika u povećanju prihoda zbog poboljšanja kvalitete inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015.

H11: Organizacijske inovacije te inovacija poslovnog modela HR NTP 2015 pozitivno utječu na razinu inovacija proizvoda

H11a: Postoji statistička razlika u organizacijskim inovacijama inovacijsko vodećih i inovacijskih sljedbenika u odnosu na neinovativna HR NTP 2015.

H11b: Postoji statistička razlika u inovacijama poslovnog modela inovacijsko vodećih i inovacijske sljedbenike u odnosu na neinovativna HR NTP 2015.

H12: Marketinške inovacije HR NTP 2015 pozitivno utječu na razinu inovacija proizvoda.

H13: Ne postoji statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih u odnosu na neinovativna HR NTP 2015.

H14: Model inovacijskog menadžmenta HR NTP moguće je primijeniti i na uslužna poduzeća – hotelijerstvo.

1.4. Znanstvene metode

U istraživanju su primijenjene sljedeće analitičke i statističko-matematičke metode:

1. u teorijskom dijelu primijenjene su razne analitičke metode:

- metodom **analize i sinteze** odvojena su inovativna od neinovativnih poduzeća, vodeća poduzeća od inovacijskih sljedbenika i onih neinovativnih, a metodom sinteze povezane su zajedničke karakteristike nužne za utvrđivanje čimbenika učinkovitosti i uspješnosti

- metodom **komparacije** uspoređen je inovacijski potencijal Hrvatske s EU-om i svijetom

- metode **dedukcije i indukcije** primijenjene su pri donošenju općih i pojedinačnih zaključaka
- metodama **apstrakcije i konkretizacije** odvojeni su bitni od manje bitnih elemenata predmetnog istraživanja,
- metode **generalizacije i specijalizacije** primijenjene su u istraživanju za dolazak s posebnog pojma do općenitijeg te obrnuto
- metodom **klasifikacije** opći je pojam podijeljen na posebne u okviru opsega pojma
- **povijesna metoda** primijenjena je u teorijskom dijelu na temelju dosad istraženih spoznaja i modela kako bi se produbila saznanja o inovacijskom menadžmentu, vrstama inovacija, procesu inoviranja, inovacijskom kapacitetu, mjerenju efikasnosti inovacija i drugim relevantnim spoznajama nužnim za empirijsko testiranje i dokazivanje postavljene hipoteze
- metoda **dokazivanja i opovrgavanja** primijenjena je kako bi se potvrdile ili odbacile postavljene hipoteze.

Primijenjene su i ostale znanstvene analitičke metode nužne za dokazivanje postavljenih hipoteza.

2. u empirijskom dijelu primijenjene su statističko-matematičke metode:


Na temelju relevantnih pokazatelja analizirao se inovacijski rezultat poduzeća (Likar *et al.*, 2011). Za mjerenje inovacijskih rezultata izabrana su dva pokazatelja:

RII: udio prihoda od inovacija proizvoda u ukupnim prihodima (%)

RMI: udio prihoda od inovacija proizvoda novih za tržište u ukupnim prihodima od inovacija (%)

Za podjelu poduzeća u inovacijske skupine, tj. za granicu podjele, određene su medijanske vrijednosti pokazatelja *RII* i *RMI*. Na taj način definirane su tri skupine poduzeća: *neinovativna poduzeća* ($RII = RMI = 0$), *inovacijski sljedbenici* (*RII* i *RMI* ispod medijanske vrijednosti) i *inovacijsko vodeća* poduzeća (*RII* i *RMI* iznad medijanske vrijednosti).

Slika 1: Podjela poduzeća na inovacijske skupine



Izvor: Autor prema Likar, B., Fatur, P., Ropret, M., Trček, D., Markič, M., Bavec, C., Škafar, M., & Rodman, K. (2011). *Referenčni model inoviranja: zaključno poročilo o rezultatih raziskovalnega projekta*. Koper: Fakulteta za management

Podjela poduzeća na spomenute inovacijske skupine s pomoću medijanskih vrijednosti primijenjena je u svim trima fazama empirijskog istraživanja. Svrha i cilj istraživanja po fazama primarno su verifikacija i razvoj teoretskog i metodološkog okvira, a zatim i usporedbe rezultata te provjere mogućeg prijenosa znanja između hrvatskih i njemačkih poduzeća.

U prvoj fazi istraživanja (i u sljedećim fazama u bivarijantnoj statističkoj analizi) za provjeru pretpostavki primijenjen je parametrijski ili neparametarski statistički test, ovisno o samoj distribuciji podataka. Vizualnim pregledom histograma, normal Q-Q plotova, box plotova, Shapiro-Wilkovim testom te koeficijentima asimetrije i zaobljenosti pokazalo se da podatci za sve tri inovacijske skupine poduzeća HR NTP nisu uobičajeno distribuirani, stoga je za provjeru hipoteza *H1* do *H3* primijenjen neparametrijski **Mann-Whitneyjev U-test** dva nezavisna uzorka kako bi se utvrdila statistička značajnost između inovativnih i neinovativnih poduzeća, tj. vodećih inovacijskih poduzeća, inovacijskih sljedbenika i neinovativnih poduzeća.

U hipotezama *H1* i *H2* uspoređene su visine i struktura inovacijskih ulaganja inovacijsko vodećih HR NTP i neinovativnih HR NTP (*H1*) te inovacijsko vodećih i inovacijskih sljedbenika HR NTP (*H2*) mjerene u skladu s metodološkim preporukama OECD-a (2005,

Priručnik iz Osla (Oslo Manual)): vlastite aktivnosti IR-a, vanjske aktivnosti IR-a, nabave postrojenja, opreme, softvera i zgrada, nabava postojećeg znanja od drugih poduzeća ili organizacija i sve ostale inovacijske aktivnosti uključujući dizajn, osposobljavanje, marketing i druge relevantne aktivnosti. Za testiranje visine i strukture inovacijskih ulaganja upotrijebljeni su cenzusni podatci koje prikuplja Državni zavod za statistiku (DZS) obrascem Inovacijske aktivnosti poduzeća (INOV) za razdoblje 2010. – 2012. Upitnik je u skladu s Eurostatovim istraživanjem Community Innovation Survey (CIS).

U hipotezi *H3* testirano je postoji li značajna razlika u efikasnosti svih skupina HR NTP (inovacijsko vodeći, inovacijski sljedbenici i neinovativni). Produktivnost inovacijskog procesa definirana je kao odnos visine inovacijskih prihoda i za to namijenjenih financijskih ulaganja (Hollanders, Celikel-Esser, 2007; Gumusluoglu, Ilsev 2009). Za to je potrebno zbrojiti podatke Državnog zavoda za statistiku (DZS) o visini financijskih ulaganja HR NTP (zbroj svih troškovnih kategorija prema metodologiji OECD-a) i visini prihoda od inovacija. Za potvrđivanje hipoteze *H4*, u svim skupinama HR NTP, uz podatke DZS-a, upotrijebljeni su financijski podatci Financijske agencije (FINA) za izračunavanje pokazatelja (ROE, ROA, ROS, ROI, dodana vrijednost po zaposlenom i ekonomičnost ukupnog poslovanja) kojima će se provjeriti jesu li inovacijska vodeća poduzeća i gospodarski uspješnija od ostalih.

U drugoj fazi istraživanja njemačka su poduzeća uzeta kao svojevrsni „benchmark” (usporedba s najboljom praksom) s obzirom na to da su unutar EU-a i diljem svijeta prepoznata kao jedna od najinovativnijih i najkonkurentnijih poduzeća (World Economic Forum, 2012; Eurostat, 2013; UNU-MERIT, 2013). Također, kao jedna od inovacijsko vodećih država u EU-u, Njemačka na nacionalnoj razini prikuplja podatke sumirane u jednoj od najcjelovitijih baza inovacijskih podataka poduzeća pod nazivom Mannheim Innovation Panel (MIP). U svrhu testiranja hipoteza (*H5 – H7*) i pripadajućih pomoćnih hipoteza (*H5a – H5f*) iz podataka koje prikuplja Mannheim Innovation Panel za razdoblje 2008. – 2010. godine upotrijebljene su varijable koje opisuju produktivnost inovacijskog procesa, visinu i strukturu ulaganja DE NTP u inovacijske aktivnosti, inovacijske sposobnosti poduzeća, uštede u troškovima i poboljšanja u kvaliteti te financijske pokazatelje.

Za utvrđivanje ulaznih (OECD-ova metodologija; visina i struktura ulaganja u inovacije) i procesnih inovacijskih čimbenika (izbor baze Mannheim Innovation Panel; organizacija i upravljanje inovacijskim procesom) DE NTP te njihovih utjecaja na inovacijski rezultat u hipotezi *H5* (i pomoćnim hipotezama *H5a* – *H5f*) primijenjeni su neparametrijski **Mann-Whitneyjevi U testovi**.

U hipotezi *H6* za testiranje statistički značajnih veza, tj. za mjerenje povezanosti između udjela ulaznih čimbenika i „nefinancijskih” procesnih čimbenika upotrijebljen je **Spearmanov koeficijent korelacije**. Statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna njemačka poduzeća niske i srednje niske tehnološke razine testirana je u hipotezi *H7*. Za testiranje rangova između dviju nezavisnih skupina upotrijebljen je neparametrijski **Mann-Whitneyjev U test**.

U trećoj fazi istraživanja na hrvatskim poduzećima niske tehnološke razine razvijenosti (HR NTP 2015) primijenjena je **metoda anketnog upitnika** za razdoblje od 2013 do 2015. godine. Upitnik je najčešće primjenjivana metoda prikupljanja primarnih kvalitativnih i kvantitativnih podataka kod mjerenja inovacijske aktivnosti poduzeća. Visokostrukturirani upitnik sastavljen je i analiziran na temelju iscrpnog pregleda relevantne literature i prethodnih istraživanja te rezultata istraživanja iz prvih dviju faza (INOVA i MIP upitnik). Prije formalnog prikupljanja podataka provedeno je pretestiranje (pilot-testiranje) u obliku osobnog intervjua s deset menadžera visoke razine HR NTP 2015.

Za testiranje hipoteze *H8* upotrijebljeni su podatci prikupljeni anketnim upitnikom koji opisuju visinu i strukturu ulaganja HR NTP 2015 u inovacijske aktivnosti. U skladu s metodologijom OECD-a (i metodologijom u drugoj fazi istraživanja), dva ulazna pokazatelja po kojima se mogu mjeriti inovacijske aktivnosti poduzeća jesu novčano ulaganje u R&D tijekom određenog razdoblja te zaposlenici koji rade na poslovima R&D-ja. Za utvrđivanje statistički značajne razlike primijenjen je neparametrijski **Mann-Whitneyjev U test**.

Da bi se ispitaio utjecaj nefinancijskih, procesnih čimbenika na inovacijsku aktivnost HR NTP 2015, primijenjene su **metode multivarijatne analize, faktorska analiza i analiza**

pouzdanosti. Multivarijatna analiza obuhvaća statističke metode kojima se istodobno analizira međusobna povezanost više od dviju varijabli. Za potrebe racionalizacije mjernih ljestvica primijenjena je **eksploratorna faktorska analiza** (*exploratory factor analysis*) s pomoću koje je reduciran velik broj elemenata inovacijskih sposobnosti na manji broj zajedničkih faktora koji opisuju i objašnjavaju njihovu međusobnu povezanost. Nakon što su utvrđeni i objašnjeni faktori inovacijskih sposobnosti HR NTP 2015 te nakon što je procijenjena unutrašnja konzistentnost svih faktora, testiranje hipoteze *H9*, tj. postojanje statistički značajne razlike u procesnim inovacijskim čimbenicima (inovacijskim sposobnostima) inovacijsko vodećih poduzeća u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015, izvršeno je neparametarskim statističkim **Mann-Whitneyjevim** testom.

U obradi izlaznih inovacijskih pokazatelja u hipotezama *H10* – *H12* primijenjeni su logički i analitički postupci **analize** i **sinteze** u cilju izdvajanja važnih svojstava, odnosa i veza te uočavanja postojećih zakonitosti. Pritom su se metodom **argumentacije** i **ilustracije** upotrijebile tablice statističkih podataka prilagođene opisanom tekstu, grafički prikazi i ostala znanstveno učestala tehnička sredstva prezentiranja rezultata istraživanja. Testiranje pokazatelja uspješnosti procesnih inovacija u pomoćnim hipotezama *H10a* i *H10b*, tj. testiranje statistički značajnih razlika u prosječnim uštedama troškova te poboljšanja u kvaliteti potaknutih inovacijom procesa, izvršeno je neparametrijskim **Mann-Whitneyjevim U testom**.

U hipotezi *H13*, kao i u prvoj fazi istraživanja, odabrani financijski pokazatelji za analizu jesu dodana vrijednost po zaposleniku, prihod od prodaje i prihod od prodaje po zaposleniku te pokazatelji profitabilnosti: povrat na prodaju, tj. profitna marža (ROS), povrat na imovinu (ROA), povrat na kapital (ROE), povrat na investirano (ROI) i pokazatelj ekonomičnosti ukupnog poslovanja. Za testiranje *H13*, tj. statistički značajne razlike u financijski izraženoj efikasnosti inovacijsko vodećih u odnosu na neinovativna HR NTP 2015, primijenjen je neparametrijski **Mann-Whitneyjev U test**.

Za potvrđivanje hipoteze *H14* primijenjena je kvalitativna analiza. Odabrano je deset vodećih hotela kojima su predstavljeni rezultati istraživanja te je na temelju **polustrukturiranog intervjua** (direktori financija, kontrolinga) ispitano je li moguće dobivenu ocjenu kroz model

na prerađivačkoj industriji primijeniti i na hotelijerstvo koje se također svrstava u industriju s nižom tehnološkom razinom, točnije znanjem intenzivnu nisku uslugu (LKIS) (Eurostat, 2008). Metode **analize** i **sinteze** primjenjuju se da bi se uočile sličnosti i razlike u elementima predloženog modela. Također, za ispitivanje teorijskih relevantnih aspekata upotrijebljena je **induktivna** metoda koja se primjenjuje u kvalitativnim istraživanjima. Dobivene informacije iz polustrukturiranih intervjua obrađene su metodom **analize sadržaja**.

Završno se metodom **sinteze** dobivenih rezultata potvrdila temeljna znanstvena hipoteza da je moguće razviti model kojim će se uspješno upravljati inovacijama u hrvatskim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti.

1.5. Doprinos znanosti

Očekivani znanstveni doprinos ovoga doktorskog rada predstavljen je u razvijenom modelu inovacijskog menadžmenta koji se temelji na cjelovitom pristupu upravljanja inovacijskim čimbenicima hrvatskih poduzeća niske i srednje niske tehnološke razine razvijenosti. Temelj za izradu ovog modela jest metodologija znanstveno utemeljenog i originalnog „referentnog inovativnog modela” (Likar *et al.*, 2011). S obzirom na to da je metodologija provjerena, prednost je ovakva pristupa dobivanje originalnih znanstvenih spoznaja koje se odnose na hrvatsko istraživačko područje upravljanja inovacijama u području industrije s niskom ili srednje niskom tehnološkom razinom. Dodatna je prednost ovakva pristupa mogućnost da se rezultati istraživanja usporede s poduzećima sličnih karakteristika iz drugih zemalja, što je nov znanstveni doprinos. Također, doprinos ovog modela jest u mogućoj primjeni metodologije na sektor usluga (hotelijerstvo), što je iznimno važno s obzirom na orijentaciju hrvatskoga gospodarstva. Navedeno se potkrepljuje sljedećim:

- analizom poduzeća razvrstanih u inovacijske grupe (vodeći, sljedbenici, neinovativni) provjerit će se povezanost inovacijskih aktivnosti te efikasnost HR NTP
- objektivno će se provjeriti primjenjivost međunarodnih istraživačkih rezultata na hrvatsko okruženje

- na temelju jasno strukturiranog i znanstveno valjanog modela te pojašnjenja inovacijskih čimbenika, HR NTP moći će kreirati ili ispraviti svoje inovacijske strategije te podići razinu inoviranja, a samim time i poslovanja
- rezultati analize te razvijeni model također mogu biti polazna točka za učinkovitija istraživanja inovacijskih uzoraka u uslužnim djelatnostima, npr. u hotelijerstvu
- dobiveni rezultati mogu biti osnova za buduća istraživanja i suradnju među državama sličnih inovacijskih kapaciteta (Slovenija i zemlje unutar i izvan EU-a).

Doprinos disertacije također je prikazan u inovativnoj upotrebi postojećih, javno dostupnih statističkih podataka prema metodologiji Europske unije koji će omogućiti potvrđivanje osnovne hipoteze rada o tome da je moguće razviti model kojim će se uspješno upravljati inovacijama u hrvatskim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti. Znanstveni doprinos rada jest da se kroz predloženi model pokuša utjecati na hrvatska poduzeća u vidu jačanja njihove inovacijske aktivnosti, tj. povećanja ulaganja u istraživanje i razvoj te osnaživanja inovacijskih kapaciteta. Konačno, doktorska disertacija kao izvorno i samostalno izrađeno znanstveno djelo služiti će kao temelj za daljnja istraživanja i opisivanje originalnih rezultata te objavljivanje u visokocitiranim domaćim i međunarodnim časopisima dostupnima znanstvenoj i stručnoj zainteresiranoj javnosti.

1.6. Struktura rada

Uz uvod i zaključak, doktorska je disertacija podijeljena u tri sadržajno povezana poglavlja. Postavljeni problem i predmet istraživanja, temeljna znanstvena hipoteza i pomoćne hipoteze te svrha i ciljevi istraživanja odredili su potrebu istraživanja koncepta inovacijskog menadžmenta i efikasnosti poduzeća niske i srednje niske tehnološke razine. Konceptualni dio ove doktorske disertacije obuhvaća drugo i treće poglavlje, dok se empirijski dio rada odnosi na četvrto poglavlje. Dakle, rezultati istraživanja sustavno su predstavljani u pet međusobno povezanih poglavlja.

U prvom poglavlju pod naslovom *Uvod* definiraju se istraživački problem i predmet doktorskog rada. Određena je svrha i postavljeni su ciljevi istraživanja. Također, postavljena je znanstvena

hipoteza koja glasi: znanstveno utemeljenim spoznajama o upravljanju inovacijama, karakteristikama inovacijskog kapaciteta hrvatskih poduzeća, značajkama hrvatskih poduzeća niske tehnološke razine, i istraženih inovacijskih čimbenika njemačkih poduzeća s niskom tehnološkom razinom moguće je razviti model kojim će se uspješno upravljati inovacijama u hrvatskim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti (HR NTP). Za potvrđivanje istraživačkog pitanja postavljene su pomoćne hipoteze koje će se testirati primjenom raznih analitičkih i matematičko-statističkih metoda.

U drugom poglavlju pod naslovom *Teorijske osnove inovacijskog menadžmenta u okruženju održivog razvoja* istražena je teorijska podloga o ulozi i značaju inovacijskog menadžmenta u okruženju održivog razvoja, a detaljno su razrađene vrste inovacija s naglaskom na modele inovacijskih procesa. Inovacijski procesi analizirani su s aspekta pojedinih faza koje su teorijski istražene kroz različite modele. S obzirom na to da se inovacijski proces sastoji od više faza, u radu se istražio i način njihova mjerenja. U svrhu razvijanja i razrade istraživačkog modela potrebno je cjelovito poznavanje utjecajnih čimbenika koji su promatrani kroz ulazne, procesne i izlazne inovacijske čimbenike.

U trećem poglavlju pod naslovom *Analiza inovacijskih sposobnosti poduzećima* istražene su inovacijske sposobnosti i inovacijski kapacitet koji se razmatra u kontekstu konkurentnosti u okruženju održive ekonomije. S obzirom na to da se inovacijski kapacitet sastoji od čitava niza karakteristika poduzeća koje potpomažu strategiju inoviranja, analizirane su vrste inovacijskih sposobnosti i njihov međusobni utjecaj. Istraživačko-razvojni kapacitet ispitan je kroz utjecaj znanja, vještina i kreativnosti. Organizacijski kapacitet jedan je od ključnih jer zahtijeva razvijene organizacijske mehanizme te njihovu usklađenost, razvijenu organizacijsku kulturu i usvajanje dobre prakse upravljanja. Proizvodni kapacitet zahtijeva mogućnost transformacije rezultata istraživanja i razvoja u proizvode koji će zadovoljiti potrebe tržišta. Stoga su, uz tehnološki kapacitet, potrebna i financijska sredstva te razvijen informacijski i marketinški sustav koji trebaju omogućiti lansiranje proizvoda na tržište, bolju konkurentsku poziciju te prihvaćanje inovacije na tržištu. Sposobnost strateškog planiranja i kontrole smatra se neophodnom zbog identifikacije internih snaga i slabosti te eksternih prilika i prijetnji, formuliranja planova te kontrole njihova izvršenja u skladu s postavljenom vizijom i misijom

poduzeća. Rezultati inovacijskog procesa i inovacijskih sposobnosti moraju se mjeriti, najčešće kroz pokazatelje veličine i rasta prodaje, rezultat inovacija te rezultat prodaje novih proizvoda.

U četvrtom poglavlju pod nazivom *Empirijsko istraživanje inovacija kod poduzeća s niskom i srednje niskom tehnološkom razinom*, koje slijedi nakon teorijskih ishodišta, provedeno je empirijsko istraživanje u tri faze. Poduzeća su podijeljena u tri inovacijske skupine: inovativno vodeća, inovacijski sljedbenici te neinovativna poduzeća. S pomoću statističkih metoda analizirana su HR NTP na temelju visine i strukture njihovih ulaganja i produktivnosti inovacijskog procesa. Testirano je jesu li inovacijsko vodeća poduzeća efikasnija u odnosu na inovacijske sljedbenike te neinovativna HR NTP. S obzirom na to da je Njemačka u skupini inovacijsko vodećih država u EU-u, na temelju baze podataka Mannheim innovation panel analizirana su njemačka poduzeća s niskom i srednje niskom tehnološkom razinom (DE NTP). Uz iscrpan pregled literature, dobiveni rezultati iz druge faze istraživanja poslužili su za istraživanje (i usporedbu) na primarnim podacima hrvatskih poduzeća s niskom i srednje niskom tehnološkom razinom (HR NTP 2015). Na temelju statističkih metoda ocijenjena je razina inovativnosti HR NTP 2015, tj. analizirani su ulazni, procesni i izlazni inovacijski čimbenici te financijska efikasnost HR PNT 2015. Sintezom rezultata predložen je model za prijelaz iz neinovativnog u inovativno vodeće poduzeće te je testirana temeljna hipoteza koja propitkuje je li moguće uspješno upravljati inovacijama u hrvatskim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti. Nakon analize i sinteze rezultata istražena je mogućnost primjene modela i na uslužne djelatnosti, konkretno na primjeru hotelijerstva.

U završnom, petom dijelu doktorskog rada, *Zaključku*, konkretizirani su i sintetizirani svi relevantni zaključci i rezultati iz teorijskog i empirijskog dijela disertacije koji potvrđuju postavljenu temeljnu hipotezu i pomoćne hipoteze. Također, istaknuta je primjena rezultata istraživanja u teoriji i praksi, opisana su ograničenja istraživanja i navedene su preporuke za poboljšanje modela upravljanja inovacijama i za buduća istraživanja. Bibliografske jedinice grupirane su prema vrsti u skupine knjiga i članaka te mrežnih izvora. Na kraju ove doktorske disertacije nalazi se popis tablica, slika i grafikona te popis priloga.

2. TEORIJSKE OSNOVE INOVACIJSKOG MENADŽMENTA U OKRUŽENJU ODRŽIVOG RAZVOJA

Pritisци konkurencije i brz tehnološki napredak povećavaju potrebu za kontinuiranom prilagodbom, poboljšanjem i inovativnošću poduzeća (Brown, Eisenhardt, 1995; Gilson, Shalley, 2004). U današnjem okruženju, koje naglašava održivi razvoj kao smjernicu za budući rast i razvoj svjetskoga gospodarstva, inovacije su jedna od ključnih pretpostavki. Opće je poznato da su inovacije ključ uspjeha, posebno u privatnom sektoru (Schumpeter, 1934, 1946) jer utječu na smanjenje troškova, poboljšanje proizvoda i usluga, otvaranje novih tržišta, – općenito potiču konkurentnost i održivost. Inovacijski menadžment dinamičan je proces u kojem se razvijaju nove i kreativne ideje, selektiraju i primjenjuju nova rješenja pa je stoga to jedna od zastupljenijih tema u znanstvenoj literaturi iz područja menadžmenta, posebno u zadnjih desetak godina. Razlog tome jest opstanak poduzeća u ekonomskim uvjetima globalizacije s orijentacijom na održivost, i to i onih profitnih koji moraju konkurirati (Schumpeter, 1942; Drucker, 1985; Kaplan, Norton, 1992; Cooper, 2005) i neprofitnih koji moraju poboljšati svoje usluge.

2.1. Pojmovno određenje i značaj suvremenog inovacijskog menadžmenta

Pri objašnjenju pojma „inovacijski menadžment” ili „upravljanje inovacijama ili „menadžment inovacija” polazište su inovacije i inovativnost! Inovacija (lat. innovare = promijeniti), koju je Schumpeter još 1934. godine definirao kao „izvođenje novih kombinacija”, danas imperativ: „one su rat: inovirati ili umrijeti” (Coopers, 2005, 4). Schumpeter inovaciju definira kao „uvod” u novi proizvod, novu metodu proizvodnje, otvaranje novog tržišta i zapravo predstavlja radikalan odmak od nečega starog. Naglašavajući da je to uvod u nešto, Schumpeter ukazuje na činjenicu da je inovacija proces, a ne samo objekt. Također, svoju definiciju ne ograničava samo na inovacije proizvoda nego otvara mogućnost za razvoj organizacijskih i procesnih inovacija.

Tijekom godina definicije raznih autora pojašnjavale su pojam inovacije. Industrijska inovacija uključuje tehničke, dizajnerske, prerađivačke, menadžerske i komercijalne aktivnosti uključene

u marketing novog (ili značajno poboljšanog) proizvoda ili prve komercijalne upotrebe novog (ili značajno poboljšanog) procesa ili opreme (Freeman, 1982). Inovacija je specifičan alat poduzetnika kojim eksploatiraju promjene kao priliku za različite poslove ili usluge (Drucker, 1985). Uspješna inovacija jest kreacija i implementacija novih procesa, proizvoda, usluga ili načina isporuke koji rezultiraju značajnim poboljšanjima u ostvarivanju željenog rezultata, efikasnosti, efektivnosti ili kvaliteti (Albury, 2005).

Ipak, u literaturi se pod inovacijom najčešće podrazumijeva uvođenje novih stvari ili metoda, to je „kombinacija ili sinteza znanja u originalnim, relevantnim, vrednovanim novim proizvodima ili uslugama” (Luecke, Katz, 2003). Jacobs i Snijders (2008) navode da je inovacija „nešto novo što se realizira s dodanom vrijednošću”. Amabile *et al.* (1996) sugeriraju da se inovacija zasniva na kreativnosti, kreativnim idejama, tj. to je „uspješna implementacija kreativnih ideja unutar poduzeća, a kreativnost osobe i tima je početak za inovaciju; ovo prvo je nužno ali nedovoljan uvjet za ovo drugo”. Inovirati ne znači imati samo „novu ideju”, već je inovacija uvijek uspješna eksploatacija neke ideje. Inovativnost predstavlja ravnotežu između kreativnosti i pragmatizma kao i između vizije i ekonomske logike (Buble *et al.*, 2010, 29).

Sveobuhvatno, cjelovitije gledanje na inovaciju i inovacijske procese s naglaskom na rezultat koji zadovoljava širi krug aktera vezanih za poslovanje konkretnog poduzeća daju Likar *et al.* (2013) naglašavajući da je inovacija stvaranje, razvoj i uvod u nove proizvode/usluge ili njihove komponente, ili nova procedura ili proces za izvršavanje poslova u korist jednog ili više dionika poduzeća.

Inovacija se često poistovjećuje s invencijom. Komponenta uspješne inovacije jest uspjeh novog „koncepta” na tržištu s naglaskom na kreativnost, a ne samo inventivnost. Invencija se odnosi na stvaranje novih ideja ili same metode, a inovacija na upotrebu bolje ideje ili metode. Cilj je inovacije pozitivna promjena koja mora povećati dodanu vrijednost. U tom smislu Freeman (1974) objašnjava da je invencija ideja, skica ili model za novi ili poboljšani uređaj, proizvod, proces, sustav... a inovacija se u ekonomskom smislu ostvaruje tek s prvom komercijalnom transakcijom.

Birkinshaw *et al.* (2008) promatraju invenciju kao jednu od faza inovativnog procesa koja je inicijalni akt eksperimentiranja iz kojeg izrasta nova hipotetska upravljačka praksa. Autori definiraju menadžment inovacija kao invenciju i primjenu prakse upravljanja, procesa, strukture ili tehnike koja je nova u znanosti i usmjerena budućim ciljevima organizacije. U kontekstu poslovanja poduzeća Roberts (1998) ističe da je inovacija = invencija + eksploatacija, što znači da invencija uključuje stvaranje i razvoj ideje u djelotvornu aplikaciju, a eksploatacija proces komercijalizacije i ubiranje koristi.

Inovacije ne moraju uvijek biti temeljene na invenciji, ali jednako tako mogu uključivati prepoznavanje, prenošenje i prilagodbu novih ideja i rješenja iz drugih zemalja, područja i organizacija. Valja naglasiti da se inovacija razlikuje od poboljšanja u tome što se vodi idejom da se učini nešto drukčije, a ne da se ista stvar radi na bolji način. Inovacija u 21. stoljeću ima eksperimentalan i evolutivan pristup, nije više samo istraživanje i razvoj, već i interakcija s partnerima, kupcima i drugim akterima (Lindgren, 2012). Takvu holističkom pristupu inovaciji najbolje odgovara shvaćanje inovacije kao „uspješne eksploatacije novih ideja” jer uključuje razne vrste inovacija (proizvodno/uslužne, procesne, tehnološke, administrativne i dr.).

Način na koji se vodi i upravlja inovacijom naziva se inovacijski menadžment. To je proces ili čitav niz aktivnosti koje se provode po pojedinim fazama u inovacijskom ciklusu od ideje do realizacije. Prema Hansenu i Birkinshawu (2007), inovacijski menadžment predstavlja aktivnu i svjesnu organizaciju, kontrolu i izvršenje aktivnosti koje vode do inovacije. Peter F. Drucker (1999) objašnjava inovacijski menadžment sa stajališta upravljanja i vođenja, naglašavajući da biti vođa koji mijenja zahtijeva volju i sposobnost za mijenjanjem onoga što je već učinjeno, a jednako tako zahtijeva i sposobnost za činiti nove i drugačije stvari. U današnje vrijeme, kada su inovacije prioritetne radi opstanka i razvoja poduzeća, upravljanje inovacijama, tj. mjerenje efekata svake pojedine faze inovacijskog procesa radi ocjene njihove učinkovitosti nije samo svrha već i potreba.

2.2. Koncept inovacija u okruženju održivog razvoja

U današnjem poslovnom okruženju, koje karakterizira visoki stupanj rizika kao posljedica globalne konkurencije i ubrzanog razvoja tehnike i tehnologije, dugoročnu održivost i konkurentnost poduzeća moguće je ostvariti samo kompetentnim i učinkovitim upravljanjem inovacijama te inovacijskim resursima. U tom pravcu naglašava se održivost kao princip poslovanja u 21. stoljeću koji potiče inovativnost i stoga sve veći broj poduzeća „lansira” ekološke, tj. „zdrave” proizvode ili znatno unaprjeđuju postojeći asortiman proizvoda i usluga. To posebno vrijedi za prerađivačku djelatnost u kojoj je održivi razvoj jedan od važnih pokretača i stimulansa za inovacije.


U konceptu održivosti i održivog razvoja javlja se više pojmova koji označavaju „zdrave”, „zelene”, „ekološke”, „održive” inovacije. Stoga je na početku potrebno utvrditi neke osnovne pojmove. Prema Church *et al.* (2008, 3), pojmove održivost (*sustainability*) i održivi razvoj (*sustainability development*) upotrijebilo je Međunarodno udruženje za očuvanje prirode i prirodnih bogatstava još 1980. godine u svojem izvještaju o strategiji svjetskog očuvanja u kojoj se održivi razvoj definira kao „integracija očuvanja i razvoja radi osiguranja da će promjene na planetu zaista omogućiti život i blagostanje ljudi”. No, u literaturi se pod održivim razvojem ipak najčešće spominje „razvoj kojim se udovoljava potrebama sadašnje, a da se pri tome ne ugrožava mogućnost budućih generacija da zadovolje svoje potrebe” (UNWCED, 1987).

Iz perspektive poduzeća, koncept održivosti promatra se s aspekta društvene odgovornosti koja se temelji na trima stupovima: ljudima, planetu i profitu (*people, planet and profit* – 3P), odnosno na konceptu trostrukog rezultata ili trostrukog konačnog ishoda – ekonomiji, ekologiji i društvu [United Nations, World Summit on Sustainable Development, www.unmillenniumproject.org, 23. 4. 2015.]. Povezujući održivost i društvenu odgovornost poduzeća, mnoge studije pokazale su njihovu pozitivnu korelaciju jer aspekti društvene odgovornosti kreiraju nove proizvode i zahtijevaju nove ili promijenjene procese, dodatna ulaganja koja potiču inovativnost. Inovacije i održivost u korelaciji predstavljaju nov način ili filozofiju upravljanja i vođenja aktivnosti poduzeća. Zato se i javlja pojam „eko-inovacija” koji predstavlja „nove proizvode i procese koji osiguravaju kupce i vrijednost u poslovanju, ali

značajno smanjuju utjecaj na okruženje” (Bartlett, Trifilova, 2010, 2). U širem kontekstu, inovacija se odnosi na „proizvodnju, asimilaciju ili eksploataciju proizvoda, proizvodnih procesa, usluga ili metoda upravljanja i poslovanja koje su novina u organizaciji i čiji rezultati kroz cijeli životni ciklus smanjuju okolišni rizik, zagađenost i ostale negativne utjecaje korištenih resursa u odnosu na alternativu” (Kemp, Pearson, 2007, 3).

Inovacije zahtijevaju veće kompetencije nego kada su u pitanju samo poboljšanja proizvoda ili procesa – one traže kreativnost i inicijativu, eksperiment, diseminaciju znanja, suradnju među zaposlenicima i dr. (Likar *et al.*, 2013).

Slika 2: Inovacije i održivost




Izvor: Prema Likar, B. (2013). *Innovation management*. Korona plus-Institute for Innovation and Technology, str. 151.

Uvažavajući koncept društveno odgovornog poslovanja, inovacije, i u proizvodima i u uslugama, trebaju sadržavati komponentu održivosti pa se stoga u literaturi i spominju „odgovorne” inovacije (*responsible innovation*) i inovator koji je „na svjetskoj razini” odgovoran kada svoje inovacije lansira na tržište. (Pavie, 2013, 3). Inovacije se po svojoj prirodi ne mogu predvidjeti, tj. njihov je ishod moguće vidjeti tek kada su lansirane kao proizvod ili usluga na tržište. Stoga, u današnjem okruženju održivog razvoja sve aktivnosti vezane za inovacije trebaju sadržavati i etičku komponentu, tj. ekološku i društvenu, uz ekonomsku. No, odgovorna inovacija ima i svoja ograničenja jer se ne može prihvatiti ona inovacija koja zadovoljava razne želje pojedinaca, zahtjeve koji mogu biti rizični u trenutku lansiranja ili bliskoj budućnosti. Zato se o odgovornosti s aspekta inovacije može raspravljati postavljanjem

čitava niza pitanja o tome kome je i za što inovacija odgovorna, što svakako zahtijeva dublje bavljenje ovom problematikom. Nema dvojbe o tome da je odgovornost moralna vrlina i da s aspekta inovacije to znači brigu za sve one kojima je ona namijenjena i na koje može izravno ili neizravno utjecati.

Slika 3: Društveno odgovorno inoviranje



Izvor: Autor

Ako žele biti uspješna i inovativna, poduzeća danas trebaju razmotriti društvene utjecaje te utjecaje okruženja na svoje operativne procese, stimulirati i motivirati zaposlene da budu kreativni, razvijati suradnju s kupcima, dobavljačima, lokalnom zajednicom i ostalim poslovnim partnerima u nastojanju da dizajniraju i razvijaju nove proizvode i usluge. Održivost nije zakonska obaveza već moralni izazov koji omogućava poduzeću opstanak i razvoj u uvjetima globalnog tržišta.

2.3. Teorijska ishodišta o vrstama inovacija i inovacijskim procesima

Još je Schumpeter (1939) naglasio da inovacije mogu biti raznolike: nov proizvod ili niz promjena na postojećem, nov proces, nova metoda proizvodnje, novo tržište, pronalazak novih sirovina i dr. Inovacija je proces stvaranja vrijednosti kojim se omogućava novitet poduzeću, dobavljačima, kupcima, tj. ona uključuje razvoj novih procedura, rješenja, nove proizvode i usluge, nov pristup marketingu. Inovacija je postala jedan od glavnih prioriteta današnjice zbog rastuće konkurencije koja tjera poduzeća da kroz inovacije nude različitu robu i usluge uz što niže cijene kako bi postigli svoje ciljeve (Porter, 1988).

2.3.1. Različiti pristupi inovacijama

Inovacija se može definirati s različitih aspekata ili područja inovativnosti pa tako u industriji inovacija uključuje tehničke, dizajnerske, proizvodne, upravljačke i komercijalne aktivnosti uključene u marketing novog proizvoda ili komercijalnog korištenja nekim procesom ili opremom (Freeman, 1982), dok u poduzetništvu podrazumijeva poseban alat, sredstvo s pomoću kojeg se iskorištavaju promjene kao prilika za različiti posao ili uslugu (Drucker, 1985), to je eksploatacija ideja, dok je u financijskom smislu to realizacija nečeg novog što donosi dodanu vrijednost (Jacobs, Snijders, 2008).

Kao prvi moderni teoretičar inovacija, Schumpeter u svojoj definiciji inovacije naglašava da je ona „uvod” u novi proizvod, metodu, novo tržište, novi izvor imovine, nova organizacija te time inovaciju definira kao proces, a ne samo kao objekt. Jednako tako, inovaciju ne ograničava samo na proizvod, već otvara mogućnost organizacijskim i procesnim inovacijama.

Definirajući inovaciju kao izvođenje novih kombinacija, Schumpeter (1934) na sljedeći način kategorizira inovaciju:

- uvođenje novih proizvoda – to su oni s kojima potrošači još nisu upoznati – ili nova kvaliteta proizvoda (inovacija proizvoda)
- uvođenje novih metoda proizvodnje (procesna inovacija)
- otvaranje novih tržišta (marketinška inovacija)
- osvajanje novog izvora opskrbe sirovina ili poluproizvoda (inovacija lanca opskrbe)
- provedba nove organizacije bilo koje industrije (organizacijska inovacija ili inovativni poslovni model).

Na tragu Schumpeterove kategorizacije, Higgins (1996) sugerira četiri vrste inovacija u poduzeću:

- proizvodne inovacije koje rezultiraju novim proizvodima ili uslugama ili njihovim poboljšanjem
- procesne inovacije koje rezultiraju poboljšanim procesima, npr. reinženjering

- menadžerske inovacije kojima se poboljšava način kako se poduzeće vodi
- marketinške inovacije koje se odnose na promociju proizvoda, cijenu i njihovu distribuciju.

Tehnološke inovacije zauzimaju istaknuto mjesto među čimbenicima povezanim s gospodarskim rastom i konkurentnošću. To potvrđuje i značaj koji im pridodaju vlade i međunarodne institucije apostrofirajući ih kao stratešku varijablu u gospodarskom razvoju. S tim u vezi, Europska komisija permanentno naglašava potrebu za podrškom i promicanjem inovacija kao odlučujućeg čimbenika gospodarskog rasta te samim time i otvaranja novih radnih mjesta. U jednom od dokumenata Europske komisije (European Commission, 2006, RICARDIS) uz inovacijske politike navodi se da pojam inovacija nadilazi same tehnološke inovacije te, primjerice, uključuje i organizacijske inovacije, upravljanje ljudskim resursima te upravljanje različitim vrstama kapaciteta unutar tvrtke.

Polazeći od Schumpeterove klasifikacije (i ostalih istraživanja), Priručnik iz Osla (Oslo Manual (OECD, 2005)) konceptu tehnoloških inovacija pridružuje i koncept organizacijske inovacije te inovacije u marketingu pa se inovacije mogu podijeliti na sljedeće:

1. *Inovacija proizvoda* jest uvođenje na tržište fizičkog proizvoda ili usluge čiji su sastavni dijelovi ili osnovna obilježja (tehničke značajke, integrirani softver, aplikacije, prilagođenost korisniku, dostupnost) **novi** ili **znatno poboljšani**. Inovacija proizvoda (novog ili poboljšanog) mora biti **nova za vaše poduzeće, ali ne nužno za vaše tržište**. Nije presudno je li inovaciju izvorno razvilo vaše ili neko drugo poduzeće ili institucija.

Često se inovacije na proizvodu odnose na promjene već postojećih karakteristika, čime je proizvod poboljšan.

2. *Inovacija procesa* jest primjena **novoga** ili **znatno poboljšanoga** proizvodnog postupka, načina distribucije proizvoda ili potporne aktivnosti za proizvode i usluge. Inovacija procesa **mora biti nova za poduzeće, ali ne nužno za tržište** na kojem djeluje poduzeće. Pritom nije važno je li inovaciju razvilo vaše ili neko drugo poduzeće ili institucija.

Uglavnom se inovacije procesa odnose na promjene u proizvodnom procesu ili procesu realizacije usluge bez utjecaja na finalni proizvod, ali od utjecaja na smanjenje troškova ili povećanje prihoda. Činjenica je da su procesne inovacije, za razliku od inovacija u proizvode, još uvijek nedovoljno istražene pa je tako, prema ispitivanju Reichhsteina i Saltera (2006, prema Veža, Prester, 2008, 3.), 37 % autora istraživalo inovacije u proizvode, a samo 1 % procesne inovacije.

3. *Organizacijska inovacija* jest **nova** organizacijska metoda u poslovnoj praksi poduzeća (uključujući upravljanje znanjem), organizaciji radnog mjesta ili odnosima s drugim subjektima kojom se poduzeće prije nije koristilo. Organizacijska inovacija mora biti rezultat strateške odluke uprave poduzeća. Isključuju se slučajevi preuzimanja i spajanja s drugim poduzećem, čak i ako su se dogodili prvi put.

Organizacijske inovacije nemaju tehnoloških elementa i ne moraju biti temeljene na formalnim R&D aktivnostima (Edquist *et al.*, 2001, 15 – 16). Sastavni dio organizacijskih inovacija jesu administrativne i tehničke inovacije. Administrativne inovacije orijentirane su na efikasnost i efektivnost upravljanja procesima u poduzeću i administrativnim sustavom (Kimberly, Evanisko, 1981; Damanpour, Evan, 1984). Administrativne inovacije neizravno su povezane s primarnom aktivnosti poduzeća i uglavnom utječu na način upravljanja. Za razliku od njih, tehničke su inovacije izravno povezane s primarnom aktivnosti i imaju za posljedicu promjene na operativnom sustavu (Damanpour, Evan, 1984).

Pojam menadžerske inovacije (*managerial innovation*) povezuje organizacijske, administrativne i upravljačke inovacije. Pojmu upravljačkih inovacija (*management innovation*) u novije se vrijeme pridaje pozornost u literaturi povezanoj s organizacijom i upravljanjem te je zamijenio podjelu na administrativne i tehničke. Hamel (2006, 75 – 76) upravljačke inovacije definira kao odstupanje od tradicionalnih načela upravljanja, procesa i praksi koje „mijenjaju način na koji se obavlja rad uprave”. Menadžerske inovacije predstavljaju novi pristup u poznavanju načina obavljanja poslova upravljanja i nove procese koji iniciraju promjene u strategiji poduzeća, strukturi, administrativnim procedurama i sustavima (Damanpour, Aravind, 2012). Menadžerske inovacije nova su organizacijska struktura, administrativni sustav, praksa upravljanja, procesi i tehnike koje stvaraju vrijednost za poduzeće (Birkinshaw *et al.*, 2008).

Primjeri tih inovacija jesu upravljanje kvalitetom (*Total quality management – TQM*), proizvodnja točno-na-vrijeme (*just-in-time manufacturing – JIT*), krug kontrole kvalitete¹ (*quality control circle*), troškovno računovodstvo (*cost accounting*), *feedback* od 360 stupnjeva² (*360 Degree Feedback*) i multidivizijska (M-forma) struktura³ (*Multi-divisional form (M-form)*).

4. *Marketinška inovacija* jest primjena **novoga** marketinškog koncepta ili strategije koja se znatno razlikuje od postojećih marketinških postupaka u poduzeću i koja nije prije primijenjena. Zahtijeva znatne promjene u dizajnu ili pakiranju proizvoda, plasiranju proizvoda na tržište, promociji proizvoda ili određivanju cijene. Isključuju se sezonske, redovite i druge rutinske promjene u marketinškim postupcima.

Važno je koliko inovacija stimulira potražnju i zadovoljava potrebe kupaca i koliko se percipira kao inovacija. Zato inovacija s aspekta kupca mora biti usmjeravana „danim ekonomskim uvjetima” (Schumpeter, 1934) koje su prethodno predvidjeli drugi prodavači.

U zadnjem se desetljeću razumijevanje inovacija i njihov utjecaj na nacionalno bogatstvo mijenja i najčešće se pod inovacijama podrazumijeva implementacija novih ili značajnije poboljšanih proizvoda (proizvod, roba, usluga), procesa, novih marketinških metoda, organizacijskih metoda u poslovnoj praksi, organizaciji djelatnika ili eksternim odnosima (OECD, 2005). Uz četiri osnovne vrste inovacija – u proizvod, proces, organizaciju i marketing – javljaju se i potpuno nove vrste, primjerice „frugal” inovacije ili „organičke” inovacije koje su vezane za strategiju poduzeća.

¹ Skupina zaposlenika koji rade isti ili sličan posao, koji se redovito sastaju kako bi identificirali, analizirali i riješili probleme povezane s poslom. Obično su to male grupe koje najčešće vodi menadžer ili voditelj koji u konačnici prenosi, tj. predstavlja rješenja Upravi poduzeća.

² Informacije prikupljene u *feedbacku* od 360 stupnjeva sadržavaju povratne informacije od podređenih zaposlenika, kolega i voditelja kao i samoprocjene samih zaposlenika. Takve povratne informacije također mogu uključivati, kada je to relevantno, povratne informacije vanjskih izvora koji stupaju u interakciju sa zaposlenikom, kao što su kupci i dobavljači ili drugi dionici.

³ Odnosi se na organizacijsku strukturu kojom je poduzeće podijeljeno u više poluautonomnih jedinica koje se vode i kontroliraju (financijskim) ciljevima iz samog središta.

Također, polazeći od značajno novih rješenja u tehnološkom smislu, novih poslovnih modela i sl., inovacije se dijele na radikalne, inkrementalne, modularne i arhitekturne. Radikalna inovacija više je usmjerena na nove tehnologije, nove poslovne modele i revolucionarne pothvate. To se ponekad naziva inovacijom „tehnološkog guranja” (*Technology Push*). Radikalne inovacije uspostavljaju novodizajnirane temeljne koncepte koji se manifestiraju kroz komponente koje su međusobno povezane u novoj arhitekturi (Henderson, Clark, 1990). Inkrementalne inovacije nastoje poboljšati postojeće sustave, što je moguće bolje, brže i jeftinije. To se ponekad naziva inovacijom „tržišnog povlačenja” (*Market Pull*). Inkrementalne inovacije prerađuju i proširuju utvrđen dizajn te se poboljšanja pojavljuju u pojedinačnim komponentama. Temeljni koncepti i veze među njima ostaju nepromijenjeni (Henderson, Clark, 1990).

Slika 4: Henderson i Clark koncepti

| | | Temeljni koncepti | |
|---|---------------|-------------------------|---------------------|
| | | Poboljšani | Poništeni |
| Veze između temeljnih konceptata i komponenti | Nepromjenjene | Inkrementalne inovacije | Modularne inovacije |
| | Promjenjene | Arhitekturne inovacije | Radikalne inovacije |

Izvor: Izradio autor prema Henderson, R. M., & Clark, K. B. (1990). Architectural innovation: The reconfiguration of existing product technologies and the failure of established firms. *Administrative science quarterly*, str. 9. – 30.

Preostala dva tipa čine modularne i arhitekturne inovacije. Modularne inovacije (primjerice, zamjena analognog telefona digitalnim) mijenjaju temeljni dizajn koncept bez promjene arhitekture proizvoda dok arhitekturne inovacije mijenjaju arhitekturu proizvoda, tj. veze među komponentama proizvoda ostavljajući nepromijenjen sam temeljni dizajn koncept (Henderson, Clark, 1990).

Slijedeći Christensena (1997) na primjeru „disk-drive” industrije, disruptivne inovacije tehnološki su jednostavne te se sastoje od komponenti „koje nisu na policama”, sastavljenih zajedno u arhitekturi proizvoda, često jednostavnijima nego li u prijašnjim pristupima. Oni koji disruptivno inoviraju ponudili su manje od onoga što su kupci na stabilnim i organiziranim tržištima htjeli te su samim time teško mogli biti početno uvedeni na takvim tržištima. Oni su ponudili drugačiji paket atributa proizvoda vrednovan samo na tržištima u razvoju koji su manje bitni i daleki razvijenijim tržištima. Christensen tvrdi da bi disruptivne inovacije mogle „pomrsiti račune” uspješnim, dobro upravljanim poduzećima koja su osjetljiva na svoje klijente, a imaju izvrsne istraživačko-razvojne rezultate. Ta poduzeća imaju tendenciju da zanemare tržišta pogodna za disruptivne inovacije jer ta tržišta imaju vrlo niske profitne marže i premala su da bi etabliranim poduzećima pružila dobre stope rasta. Dakle, disruptivna tehnologija pruža primjer da savjeti „priznatog” poslovnog svijeta – „usredotočiti se na kupca”, „ostati blizu kupca” ili „slušati kupca” – ponekad mogu biti i strateški kontraproduktivni.

U konceptu održivosti i održive ekonomije javljaju se i pojmovi (pogledati poglavlje 2.2.) kao što su „zelene”, „eko”, „održive” inovacije kojima je zajedničko da u svoja inovativna rješenja uz ekonomsku uključuju ekološku i društvenu komponentu. Osnovno je da inovativna rješenja reduciraju negativne utjecaje na okruženje uz istovremeno uvažavanje socijalne komponente i pri realizaciji inovacije i u njezinoj komercijalizaciji i upotrebi.

Inovacije se mogu promatrati i s aspekta veličine i vrste poduzeća (privatno ili javno, malo ili veliko), što se u pogledu ciljeva i različitosti tehnike upravljanja može odraziti na način upravljanja inovacijom. Inovativna sposobnost poduzeća može se promatrati i s obzirom na situaciju u okruženju koje može biti turbulentno ili stabilno te se shodno tome mijenja i način upravljanja.

No, bez obzira na vrstu inovacije može se zaključiti:

- inovacija se uvijek temelji na novoj ideji, nečemu novome ili znatno poboljšanome
- potrebna je i ekonomski isplativa
- osigurava konkurentsku prednost i održivost.

Inovacijski menadžment jest disciplina upravljanja procesima u inovaciji i može se koristiti za razvoj svih prije spomenutih inovacija.

2.3.2. Istraživanje i razvoj (R&D)

Dugoročna održivost i konkurentnost tvrtke ostvariva je jedino kompetentnim i učinkovitim inovacijskim menadžmentom te inovacijskim resursima. Iz tradicionalne perspektive, to je jedan od zadataka odjela istraživanja i razvoja (u daljnjem tekstu: R&D). OECD definira R&D kao „... kreativan rad na sistematičan⁴ način s ciljem povećanja znanja, uključujući ljudsko znanje, kulturu i društvo, te primjenu toga u razvoju novih aplikacija”. R&D obuhvaća i formalni R&D u namjenskim R&D odjelima ili laboratorijima te neformalni ili povremeni R&D koji se izvodi u ostalim odjelima poduzeća (OECD, 2002).

R&D obuhvaća tri aktivnosti: temeljna (osnovna) istraživanja, primijenjena istraživanja i eksperimentalni razvoj. Temeljno istraživanje jest eksperimentalni i teorijski rad namijenjen ponajprije stjecanju novih, „temeljnih” znanja o pojavama i promatranim činjenicama, bez neke određene aplikacije ili upotrebe. Primijenjeno istraživanje također je izvorno istraživanje u vidu stjecanja novih znanja. Međutim, istraživanja su usmjerena prvenstveno prema specifičnim praktičnim ciljevima. Eksperimentalni razvoj podrazumijeva sustavni rad uz primjenu postojećih znanja stečenih istraživanjem i/ili praktičnim iskustvom, usmjeren na proizvodnju novih materijala, proizvoda ili uređaja, uvođenje novih procesa, sustava i usluga ili bitno unapređenje onih koji su već proizvedeni ili instalirani (OECD, 2002).

Nobelius (2004) je istaknuo pet generacija usmjerenja upravljanja istraživanjem i razvojem. Tijekom prve generacije istraživanja i razvoja (od sredine 1960-ih do ranih 1970-ih) proces R&D-ja bio je usmjeren na guranje tehnologije nizvodno prema tržištu. Tijekom druge generacije istraživanja i razvoja (od početka do sredine 1970-ih) naglasak je stavljen na marketinške napore za povećanje volumena prodaje. U takvu okruženju fokus je bio na efektu

⁴ Pojam sistematičan odnosi se na svrhovite napore prije nego na slučajna otkrića (Arundel, 2008).

povlačenja s tržišta, tj. ideje koje su potekle s tržišta trebale su se razvijati i oplemenjivati unutar R&D-ja. Nadalje, treća generacija istraživanja i razvoja (od sredine 1970-ih do sredine 1980-ih) može se prepoznati po kontroli i smanjenju troškova. Ovakav snažan proces usredotočen je na povezivanje tehnoloških mogućnosti s tržišnim potrebama. Sljedeće identificirano razdoblje obuhvaća vrijeme od ranih 1980-ih do sredine 1990-ih u kojem su se poslovne strategije vratile na osnovnu djelatnost, sve pod paradigmom konkurencije utemeljene na vremenu. Što se tiče procesa R&D-ja, istaknut je novi proces razvoja proizvoda, a integracijska paralelizacija aktivnosti predstavljena je kao čimbenik uspjeha u težnji za brzinom. Konačno, peta generacija aktivnosti istraživanja i razvoja, od sredine 1990-ih nadalje, sva je u svjetlu povećane globalne konkurencije. Istraživanje i razvoj treba stupiti u interakciju s poslovnim okruženjem, stavljajući veći naglasak na sposobnost koordiniranja i integracije sustava različitih dionika te jačanje potrebe za djelotvornom i učinkovitom integracijom koherentne cjeline. Upravljanje R&D-jem razvilo se iz tehnološki i tržišno orijentiranog, interno integriranog, u globalnu integraciju. Od kraja 1990-ih godina upravljanje znanjem čini jezgru suvremenog upravljanja R&D-jem. Ključna sintagma jest intelektualno vlasništvo, a bit je inovacija.

Nažalost, u mnogim djelatnostima i poduzećima R&D odjel nema više resursa za razvoj novih vještina vlastitim snagama, već se mora osloniti na kompetentne unutarnje i vanjske partnere. Treba uključiti radnike sa svih razina u kreativnom doprinosu razvoja tvrtke, proizvodnje i marketinga. Primjenom odgovarajućih alata za upravljanje inovacijama menadžment može potaknuti i razvijati kreativne struje cijele radne snage prema kontinuiranom razvoju tvrtke. Međunarodna konkurencija, sve zahtjevniji kupci, brz tehnološki razvoj kao i nove smjernice i norme (npr. standardi zaštite okoliša) predstavljaju visoke zahtjeve za razvoj i upravljanje novim proizvodima i uslugama. Sposobnost kreacije razvojnog procesa koji je usmjeren prema kupcima, a istovremeno je troškovno i vremenski efikasan, uz zadovoljenje pravnih, socijalnih i ekoloških zahtjeva jedna je od važnih karika za uspjeh poslovanja. Životni vijek proizvoda sve je kraći, a sve veća konkurencija tjera poduzeća i menadžment da što brže kreiraju i lansiraju proizvode, ali ne na štetu kvalitete te zadovoljstva kupca. Inovacijsko vodeća poduzeća mogu si u tom slučaju dozvoliti ipak malo veći vremenski luksuz, što se ne bi moglo reći i za inovacijske sljedbenike.

2.3.3. Karakteristike pojedinih modela inovacijskih procesa

Razvojem inovacijskih koncepata razvijali su se i razni modeli inovacijskih procesa (Carlsson *et al.*, 2002; Godin, 2006) čija je zajednička karakteristika da više ili manje korektno opisuju ili vizualiziraju inovacijske aktivnosti. Neki modeli opisuju životni ciklus inovacije u obliku *S* logističke funkcije koja se sastoji od triju zasebnih faza – pojave, rasta i zrelosti (Howard, Guile, 1992, 3). Neki naglašavaju karakteristike inovacija koje su definirane u skladu s razvojnim fazama inovacijskog procesa – invencijom, razvojem, realizacijom i distribucijom (Maidique, 1980) – dok linearni modeli inovacije općenito razlikuju pronalazak (invenciju), područje primjene rezultata inovacije, njezin razvoj, dizajn i korištenje (Niosi, 1999; Godin, 2006) za jednostavan opis inovacijskog procesa.

Razumijevanje inovacija kao procesa aktivnosti izazov je za inovatore, što se vidi iz sve veće složenosti inovacija koje su određene situacijom u okruženju u kojem djeluju, tj. rastućim znanjem, izvorima informacija, mogućnošću primjene.

Jednostavni linearni modeli inovacijskih procesa mogu se naći u najranijim radovima (Usher, 1954, 1955) kao i u suvremenijim radovima (Kamal, 2008; Baregheh *et al.*, 2009). Razlikuju se po broju i sadržaju faza, no općenito se može zaključiti da su im zajedničke sljedeće faze (Kotsemir, Meissner, 2013):

- ideja (invencija) ili „nešto novo” (proizvod, usluga ili proces – tehnološki ili organizacijski)
- razvoj (proizvodnja, izrada) nečega novog
- komercijalizacija (difuzija, „prodaja”) nečega novog

Tablica 1 prikazuje razvoj inovacijskih modela kroz povijest.

Tablica 1: Razvoj inovacijskih modela

| Generacija | Razdoblje | Autori fundamentalnih ideja | Inovacijski modeli | Najveća značajka modela |
|-------------------|--|---|--------------------------------------|--|
| 1 | Od 1950-ih do kasnih 60-ih | | Tehnološko guranje | Linearni proces |
| 2 | Od kasnih 1960-ih do prve polovice 70-ih | Myers i Marquis (1969) | Tržišna (potreba) povlačenje | R&D po željama korisnika |
| 3 | Druga polovica 1970-ih do kraja 80-ih | Rosenberg (1979) Rothwell i Zegveld (1985) | Model spajanja Interaktivni model | Interakcija različitih funkcija Interakcija s istraživačkim centrima i tržištem |
| 4 | Kraj 1980-ih do ranih 90-ih | Kline i Rosenberg (1986) | Integrirani model | Istovremeni proces s povratnim petljama; „Model povezan lancem” |
| 5 | 1990-ih | Rothwell (1992) | Mrežni model | Integracija sustava i mreže (SIN) |
| 6 | 2000-ih | Chesbrough (2003) | Otvorene inovacije | Inovacijska suradnja i višestruki eksploatacijski putevi |
| 7 | 2010-ih | | Otvoreni inovator | Focus na pojedinačnim i okvirnim uvjetima pod kojima se postaje inovativan |

Izvor: Prilagođeno prema Kotsemir, M., & Meissner, D. (2013). Conceptualizing the innovation process - Trends and outlook basic, *Basic research program working papers series: Science, Technology and Innovation*, WP BRP 10/STI/2013, str. 5.

Najznačajnije faze razvoja inovacijskih modela vezuju se za drugu polovicu 20. stoljeća, tj. od 60-ih do 80-ih godina kada su autori uglavnom bili više usmjereni na jednostavno shematsko prikazivanje modela upravljanja procesima. Inovacijski model opisivao se kroz fazu prepoznavanja potrebe za inovacijom, kreiranjem inovacije, usvajanjem i njezinom primjenom

(Kinght, 1967, Bessant, Tidd 2007). Nadopunjava se i s primjenom istraživanja i tehnologije nakon inicijalne faze, uključujući razvoj i dizajn (Carlsson *et al.*, 1976), pa sve do potrebe poduzimanja aktivnosti oko razvoja novih proizvoda i njihove realizacije i distribucije na tržištu, odnosno tehnološkog pritiska (*technology push*) (Myers, Marquis, 1969; Maidique, 1980). U tom razdoblju intenzivira se konkurencija i investicije u novi proizvod zamjenjuju racionalnija tehnička rješenja (Mensch *et al.*, 1980), a glavni je cilj bio odgovoriti na zahtjeve tržišta. Dominirali su jednostavni linearni pristupi koji su počeli naglašavati izum ili invenciju (*Invention-led*) s uključivanjem u inovativan proces faze izuma (invencije), prevođenja i komercijalizacije (Merrifield, 1986).

Od 1980-ih pa do početka 21. stoljeća napuštaju se linearni pristupi i razvijaju složeniji cjelovitiji modeli koji su povezivali sve faze inovacijskog procesa. Razvijali se u poduzećima, posebno tehnički usmjerenima, kao i u znanstvenim institutima kroz projektni pristup. Pojedinačne faze inovacijskog procesa počinju se preklapati, a ponekad između pojedinih faza postoji „povratna petlja” (*feedback loops*), što podrazumijeva transfer znanja i tehnologije u temeljna, primijenjena i razvojna istraživanja. Kline i Rosenberg 1986. razvijaju model „povezanog lanca” (*chain-linked model*) smatrajući inovacijski proces paralelnim procesom uključenim u sve korporativne funkcije, a Rothwell i Zegveld (1985) šire tradicionalni linearni pristup na povezivanje s poslovanjem poduzeća i vanjskim znanstvenim institucijama. Cjelovitost inovativnog procesa podrazumijeva uključivanje ekonomskog pristupa, tj. od ciklusa razvoja proizvoda ili procesa do ciklusa tržišta, koje znači širenje inovacije unutar geografskog područja i pojedine industrije kao i njezino prihvaćanje na tržištu (Rogers, 1995). Razumijevanju inovativnog upravljanja doprinio je britanski sociolog Roy Rothwell koji se smatra pionikom industrijske inovacije. Promatranjem povijesti razvoja inovacijskog procesa može se zaključiti da je svaka nova generacija odgovor na značajne promjene na tržištu koje su se događale u drugoj polovici 20. stoljeća, primjerice ekonomski rast, industrijska ekspanzija, jačanje konkurencije, inflacija i stagflacija, nezaposlenost i ograničenje resursa itd. Početkom 21. stoljeća počinje dominirati stav da je upravljanje inovacijama interni proces i funkcija te se razmišlja se o konceptu „otvorenih inovacija” (*Open Innovation*) (Chesbrough, 2006). Inovacija se više ne smatra procesom, već uključuje različite funkcije i institucije.

Razdoblje iza 2010. godine pa do danas smatra se generacijom u nastajanju u kojoj se naglasak sve više stavlja na pojedinačne zahtjeve i okvire unutar kojih se razvija inovativan proces. Znanje postaje javno, tj. razvoj novih tehnologija i znanje poduzeća postaju sve ovisniji o eksternom znanju i tehnologijama koji su javno dostupni ili su u vlasništvu pojedinih poduzeća ili znanstvenih institucija. Razne javne i privatne istraživačko-razvojne institucije i sveučilišta doprinose razvoju i širenju postojećeg javno dostupnog znanja. Oni su i partneri i osiguravatelji usluga za pružanje vanjskih usluga kao dijela inovacijskog procesa, dok su R&D aktivnosti unutar poduzeća pretpostavka za implementaciju inovacijskih aktivnosti „u kući”, ali i upotrebu eksternih izvora za inovacije (Gokhberg *et al.*, 2012). Na temelju analize razvoja inovacijskih modela Kotsemir i Meissner (2013) smatraju da će se oni konceptijski razvijati kroz klastere i nacionalne inovacijske sustave kao kombinacija regionalnih i ambijentalnih modela (Montresor, Marzetti, 2008; Bas, Kunc, 2009), ekološke inovacijske sustave kao „eco-friendly” modeli (Coenen, Lopez, 2010; Gee, McMeekin, 2011; Chave *et al.*, 2012) te modeli koji će uključivati lokalnu dimenziju, odnosno razvijat će se neki novi inovativni procesi koji nisu povezani s prijašnjim generacijama.

Zaključno, može se istaknuti da u suštini postoje dva pristupa analizi inovacijskih procesa: prvi je pristup „inovacijskog menadžmenta” usmjeren analizi strategije na razini poduzeća u različitim socioekonomskim i političkim uvjetima, a drugi je konceptualni pristup u kojem je fokus na razvoju inovacijskih modela i njihovoj teorijskoj podlozi. Analizom tih pristupa dolazi se do spoznaje da postoji prijelaz s makrorazine na mikrorazinu u teorijskom pristupu inovacijskim modelima i modelima inovacijskog menadžmenta. Analiza zadnjih pedesetak godina pokazuje da razvoj inovacijskih modela konceptualno nije bio linearan i da inovacija nije rezultat već proces i tijek raznih aktivnosti kao kombinacije postojećeg znanja i ciljanog stvaralačkog znanja u cilju pronalaženja rješenja koja prije nisu postojala.

2.4. Analiza inovacijskih procesa

Proces je niz logično povezanih aktivnosti i zadataka koje završavaju nekim rezultatom. Uobičajeno, svaki proces ima ulaznu vrijednost ili *input* koja se pretvara u rezultat ili *output*, a između je logički niz aktivnosti i zadataka (kojih može biti više), već prema složenosti procesa.

Shodno tome, i inovacijski se proces sastoji od aktivnosti koje su povezane procesnim pristupom od stvaranja ideje do njezine realizacije. Zadatci koji se izvode logički su povezani s ciljem postizanja željenog rezultata, imaju poseban redoslijed, dok su ulazne i izlazne vrijednosti jasno definirane (Davenport, 1993). Adam Smith bio je jedan od prvih ljudi koji su opisali poslovne procese. Još u 18. stoljeću razvio je ideju podjele rada prema kojoj se rad može podijeliti u niz jednostavnih zadataka koje obavljaju specijalizirani radnici. Promatrajući radnike u tvornici čavala, shvatio je da bi se produktivnost mogla povećati za 240 puta kada bi se proces podijelio u zasebne specijalizirane korake. Radi jačanja konkurentnosti, procesni se pristup sve češće naglašava u poslovanju poduzeća, posebno zbog potreba jačanja kvalitete, orijentacije na potrošače i općenito uspješnijeg poslovanja. Napušta se funkcijski pristup organiziranosti poslovanja i zamjenjuje se procesnom orijentacijom, procesnim razmišljanjem, procesnim mjerenjem i sl. Procesna orijentacija podrazumijeva holistički pristup u kreiranju vrijednosti, pri čemu procesno razmišljanje podrazumijeva kros-funkcijsko, orijentirano potrošačima i važno za brzinu, fleksibilnost, adaptibilnost i kvalitetu usluge.

Upravljanje inovacijskim procesom nalik je upravljanju svakim drugim projektom iako ovdje postoji veći rizik jer se radi o razvoju i odabiru ideje te njezinoj transformaciji u inovaciju. Način kako će se upravljati inovacijskim procesom ovisi o tome u kakvoj se formi inovacija javlja. No, bez obzira na vrstu, upravljanje inovacijskim procesom vrlo je složeno jer treba voditi računa o različitim inovacijskim aktivnostima (Likar, 2013). Istraživanja o inovacijskim procesima generirala su čitav niz konceptijskih modela koji na jednostavniji ili složeniji način prikazuju razvoj inovacije. Činjenica je da modeli upravljanja inovacijskim procesima postaju sve složeniji, više interdisciplinarni, integrirani i više povezani s okruženjem, tj. među pojedinim organizacijama (Eveleens, 2010).

2.4.1. Faze inovacijskih procesa

Svi modeli imaju određene faze koje se ponekad nazivaju stupnjevima, dijelovima, elementima ili glavnim aktivnostima te su poredane uglavnom nekim linearnim redom. Koncept inovacijskih procesa korisno je promatrati po fazama jer se tako mogu identificirati vodeći procesi ili neka ograničenja (Hartley, 2006). Takav linearan pristup pogodan je za upravljanje zbog jasnoće i korisnosti, no neki autori (Mulgan, Albury, 2003; Tidd, Bessant, 2005) smatraju da je prejednostavan. Kritičari linearnog modela također primjenjuju fazni pristup, no također priznaju da se mnogo povratnih petlji i ciklusa odvija prije nego što se proces nastavi. Primjera radi, Tidd i Bessant (2005) te Jacobs i Snijder (2008) prihvaćaju Cooperov „stage-gate” model (1986) u kojem su prve faze od stvaranja ideje do odabira manje linearne i imaju više povratnih petlji, dok se u kasnijim fazama primjenjuje formalniji i krući postupak.

U nastavku se daje pregled autora i njihovo razumijevanje inovacijskih procesa po pojedinim aktivnostima ili dijelovima koji će se iskazati kroz izraz „faza”:

Tablica 2: Faze inovacijskog procesa

| Autor | I. faza | II. faza | III. faza | IV. faza | V. faza | VI. faza | VII. faza |
|----------------------------------|----------------------------|---|----------------------------------|--|---------------------------------------|-----------------|------------------|
| Rogers (1962) | Znanje (spoznaja) | Ubjeđenost | Odluka | Primjena | Potvrđivanje | | |
| Cooper (1986) | Ciljano ispitivanje | Izgradnja poslovnog modela | Razvoj | Testiranje i potvrđivanje (validacija) | Lansiranje | | |
| Rothwell (1994) 3G | Stvaranje ideje | Istraživanje dizajna i razvoj | Proizvodnja prototipa | Proizvodnja | Marketing i prodaja | Marketing | |
| Van der Ven <i>et al.</i> (1999) | Inicijalno razdoblje | Razvojno razdoblje | Razdoblje primjene i završetka | | | | |
| Nooteboom (2001) | Nova kombinacija | Konsolidacija | Generalizacija | Diferencijacija | Reciprocitet | | |
| Mulgan i Albury (2003) | Stvaranje mogućnosti | Praćenje i stvaranje prototipa perspektivne ideje | Replikacija i postupno povećanje | Analiza i učenje | | | |
| Herstatt <i>et al.</i> (2004) | Stvaranje i procjena ideje | Koncept razvoja | Razvoj | Razvoj prototipa i testiranje | Proizvodnja; uvod na tržište; širenje | | |

| Autor | I. faza | II. faza | III. faza | IV. faza | V. faza | VI. faza | VII. faza |
|------------------------------|---|-----------------------------------|--|---|----------------|-----------------|----------------------|
| Verloop (2004) | Stvaranje i kristalizacija ideje | Razvoj i prikazivanje | Ulaganje i priprema za lansiranje | | | | |
| Cormican i O'Sullivan (2004) | Analiza okruženja i identificiranje prilika | Stvaranje inovacije i ispitivanje | Planiranje projekta i određivanje tima | Provođenje plana implementacije proizvoda | | | |
| Tidd i Bessant (2005) | Istraživanje | Odabir | Nabava | Izvršenje | Lansiranje | Održavanje | Učenje i reinovacija |
| Andrew i Sirkin (2006) | Stvaranje ideje | Komercijalizacija | Realizacija | | | | |
| Hansen i Birkinshaw (2007) | Stvaranje ideje | Pretvaranje ideje | Širenje ideje | | | | |
| Jacobs i Snijders (2008) | Varijacija | (Unutarnja) Selekcija | Realizacija | (Vanjska) Selekcija/Opstanak | Porast | Učenje | |

Izvor: Prilagođeno prema Eveleens (2010). Innovation management; a literature review of innovation process models and their implications. *Science*, 800, str. 5. – 6. i Saunila, Ukko (2012) A conceptual framework for the measurement of innovation capability and its effects, *Baltic Journal of Management*, 7 (4), str. 359.

Moguća je i detaljnija razrada pa tako Australaska akademija znanosti, tehnologije i inženjeringa inovacijski proces promatra kroz devet tipičnih faza koje se mogu vidjeti u tablici 3.

Tablica 3: Tipične aktivnosti u inovacijskom procesu

| Faza | Opis | Tipična aktivnost |
|-------------|--------------|---|
| I | Ideja | Istražiti mogućnost na tržištu |
| II | Resursi | Organizirati ljude, osigurati financije i ostale pretpostavke da se usklade ciljevi unutar poduzeća |
| III | Istraživanje | Istražiti mogućnosti |
| IV | Patent | Zaštititi intelektualno vlasništvo |
| V | Dizajniranje | Model i testiranje za potrebe korisnika |
| VI | Razvoj | Poboljšati |
| VII | Realizacija | Započeti s proizvodnjom |
| VIII | Prodaja | Oglasiti i informirati ljude |
| IX | Usluga | Komunicirati s potrošačima |

Izvor: Prilagođeno prema Australian Academy of Technology, Sciences and Engineering, <http://digbig.com/4wxmw> (preuzeto 18. 3. 2014.)

Vidljivo je da se inovacijski proces objašnjava kroz minimalno tri do maksimalno devet faza, no najčešće se identificiraju četiri faze. Uglavnom svi modeli polaze od stvaranja ili kreiranja ideje, što je inicijalno razdoblje u kojem se analiziraju okruženje i prilike. Druga faza jest pretvaranje ideje, tj. razvojno razdoblje stvaranja inovacije i njezina prototipa. Treća je faza ulaganje u pripremu za proizvodnju, proizvodnja i lansiranje, dok četvrta faza obuhvaća testiranje i potvrđivanje prototipa, odnosno analizu i učenje kako bi se eventualne slabosti otklonile ili nešto poboljšalo. Sljedeće faze (V, VI, VII) uglavnom se odnose na prodaju i marketing te već spomenuto učenje kako bi se inicijalna ideja poboljšala. Eveleens (2010) u svojem istraživanju literature o modelima inovacijskog procesa zaključuje da su osnovne faze

sljedeće: stvaranje ideje, odabir, razvoj i izrada prototipa, primjena/lansiranje, faza nakon lansiranja i učenje/ocjena.

2.4.2. Mjerenje inovacijskih procesa

Da bi se shvatilo je li poduzeće uspješno u usvajanju inovativnog rada, praksi i provođenju inovacijske strategije, potrebno je mjeriti proces inoviranja. U osnovi, ako je poduzeće inovativno, onda su promjene prihvaćene, a njihovi ukupni poslovni pokazatelji trebali bi odražavati pozitivan učinak (Likar, 2013). Mjerenje općenito ima svoju svrhu – kvantitativno ocijeniti efikasnost i efektivnost neke aktivnosti, postupka ili procesa (Neely, 2005; Radnor, Bures, 2007). Mjerenjem se postižu poboljšanja u ponašanju pojedinaca, jača motiviranost, poboljšava se izvođenje aktivnosti, što sve utječe na rast produktivnosti, ekonomičnosti, tj. općenito se postiže bolja efikasnost poslovanja. Mjerenje rezultata poslovanja složen je proces koji također ima svoje faze: kreiranje, implementaciju, upotrebu i održavanje sustava mjerenja (Neely *et al.*, 2000). Taj proces nije jednostavan linearni slijed od kreiranja do upotrebe pokazatelja u svrhu realizacije strategije, već zahtijeva razvijanje i korekciju na različitim razinama u skladu s promjenama situacije u poduzeću. Inovacija se vodi na način da se sagledaju mogućnosti i veze, da se utvrdi interakcija ili povezanost između dviju ili više odvojenih činjenica, što u konačnici i iskorištava. Taj je proces jako složen i da bi se njime moglo dobro upravljati, treba voditi računa o planiranju inovacije, inovativnom procesu, upravljanju projektom i tehnologijom, financiranju, kompetitivnoj inteligenciji, tehnološkom nadzoru i usporedbi s najboljom praksom (benchmarking) (Likar, 2013)

Prema Gamal *et al.* (2011), pokazatelji inovacijskih procesa mogu se ugrubo kategorizirati promatranjem njihova razvoja kroz četiri generacije koje su progresivno postale složenije i značajnije (tablica 4).

Tablica 4: Razvoj inovacijske metrike kroz generacije

| Prva generacija Input pokazatelji (1950. – 1960.) | Druga generacija Output pokazatelji (1970. – 1980.) | Treća generacija Pokazatelji inovacija (1990. – 2000.) | Četvrta generacija Pokazatelji procesa (2000. + u nastajanju) |
|--|--|---|--|
| R&D izdatci | Patenti | Istraživanja o inovacijama | Znanje |
| S&T djelatnici | Publikacije | Indeksiranje | Neopipljiva imovina |
| Kapital | Proizvodi | Benchmarking | Umrežavanje |
| Tehnički intenzitet | Promjena kvalitete | inovacijske sposobnosti | Potražnja |
| | | | Klasteri |
| | | | Tehnike upravljanja |
| | | | Rizik/povrat |
| | | | Dinamički sustav |

Izvor: Centar za akceleraciju inovacija, George Washington University, 2006. U: Gamal, D., Salah, T., & Elrayyes, E. N. (2011). How to measure organization innovativeness. *Technology Innovation and Entrepreneurship Center*, str. 10.

Prva generacija metrike označava linearnu koncepciju inovacija koja se fokusira na inpute kao što su ulaganja u R&D, troškovi za edukaciju, troškovi ulaganja, istraživačko osoblje, tehnološki intenzitet i sl. Druga generacija upotpunjava pokazatelje inputa računajući na outpute znanosti i tehnologije (S&T – science and technology). Tipični su primjeri broj patenata, znanstvenih publikacija, broj novih proizvoda i procesa, high-tech trgovine i sl. Treća generacija još više produbljuje pokazatelje inovacija oslanjajući se na istraživanja i povezanost s javno dostupnim podacima. Fokus je na benchmarking analizi i rangiranju na temelju inovativnog kapaciteta nacije. Problem se javlja u valjanosti međunarodnih podataka i uključivanju usporedivosti inovacija u uslužnom sektoru. Sadašnja četvrta generacija više uključuje pokazatelje znanja jer se smatra da je ono temelj stvaranja inovacija. No znanje je vrlo složen pojam i može se izraziti pokazateljem koji uključuje razna ulaganja u znanje i pokazatelje mjerenja uspjeha. Karakteristika suvremene inovacije ukazuje na otežano inoviranje bez suradnje s drugim institucijama, posebno kada se radi o kompleksnim tehnologijama koje zahtijevaju intenzivno znanje. Danas je znanje umreženo i globalno, što zahtijeva kreiranje raznih pokazatelja kada su u pitanju strateška partnerstva, licenciranje, neformalna suradnja i razmjena znanja, organiziranje u klaster i sl.

Ulazni inovacijski čimbenici

Ulazni inovacijski čimbenici ocjenjuju način na koji su organizirane inovacijske aktivnosti te način na koji se dodjeljuju sredstva, tj. mjere na koji su način sredstva uključena u inovacijski proces. Ti čimbenici većinom mjere intelektualni, ljudski ili tehnološki kapital (Parthasarthy, Hammond, 2002; Hagedoorn, Cloudt, 2003). Dva ulazna pokazatelja po kojima se mogu mjeriti inovacijske aktivnosti poduzeća opisuju se u Priručniku iz Frascatija (Frascati Manual; OECD, 2002): novčano ulaganje u R&D tijekom određenog razdoblja i osoblje koji radi u R&D-ju (sve osobe zaposlene izravno na R&D-ju te oni koji pružaju izravne usluge, npr. R&D menadžeri, administratori i uslužno osoblje). Osnovna mjera monetarnih R&D rashoda sastoji se od „unutarnjih izdataka” i „vanjskih izdataka”. Unutarnji izdatci jesu svi izdatci za R&D koji se obavljaju unutar statističke jedinice (poduzeća) ili sektora gospodarstva u određenu razdoblju, neovisno o izvoru sredstava. Vanjski izdatci pokrivaju izdatke za R&D obavljene izvan statističke jedinice (npr. vanjski partneri ili izvođači izvan poduzeća) ili sektora gospodarstva u određenom razdoblju (OECD, 2002). Temeljeno na više od 1300 opservacija, istraživanje Peters i Schmiele (2011) na podacima panela Mannheim Innovation Panel (MIP) potvrđuje da poduzeća koja obavljaju R&D aktivnost imaju znatno više dobiti u budućim godinama u odnosu na poduzeća bez R&D aktivnosti. Visoke razine intenziteta istraživanja i razvoja nisu nužno dokaz dobre inovativne prakse, one jednostavno mogu maskirati neučinkovitost procesa (Cebon, Newton, 1999, Dodgson, Hinze, 2000). Međutim, jasno je da je odgovarajuće financiranje vrlo važan ulazni čimbenik u inovativnom procesu. Podatci o izdatcima, uglavnom zbog njihove dostupnosti, već su dugo popularna ulazna „proxy” mjera inovacija (Adams *et al.*, 2006).

Poželjno je u istraživanje uključiti R&D pokazatelje, no osnovna je zadaća integrirati i razumjeti doprinos R&D-ja uzimajući u obzir i ne-R&D ulazne čimbenike inovacijskog procesa. Također, bilo bi vrlo korisno imati pregled uravnoteženosti R&D i ne-R&D aktivnosti kao i uzorak tih ravnoteža u pojedinim industrijama. Šire razumijevanje ovih distribucija i varijacija u pojedinim industrijama iznimno je važno za kreiranje inovacijske politike (OECD, Priručnik iz Osla (Oslo Manual)). Ako se inovativna sposobnost mjeri samo R&D pokazateljima, postoji vjerojatnost da inovativnost nekog poduzeća neće biti odgovarajuće prikazana te će mnoga poduzeća biti klasificirana kao neinovativna ili će čak biti isključena iz inovacijskih studija (Arundel *et al.*,

2008; Cuervo-Cazurra, Un, 2010). Kreatori državnih poticajnih politika pa i sama akademska zajednica uvelike zanemaruju mnoga poduzeća koja ne sudjeluju u formalnom R&D-ju. Mjerenje isključivo ulaznih pokazatelja zna biti problematično jer govori koliko je sredstava uloženo, ali ne i koliko ih je ostvareno. Ulazne mjere također podcjenjuju i manje inovacijske aktivnosti, npr. manja poduzeća nemaju prilike ulagati u istraživanje i razvoj. Zbog toga ulazne mjere ponekad ne odražavaju stvarnu sposobnost inoviranja (Albaladejo, Romijn, 2000).

Ako se polazi od jednostavnog poimanja da je inovacija = ideja + novi proizvod/usluga + implementacija na tržištu, onda je važan ulazni inovacijski čimbenik i sama ideja. Do ideje se dolazi iz raznih internih i eksternih izvora te treba imati potporu u organizacijskim i metodološkim rješenjima. Sljedeći je korak sistematična evaluacija ideje i planiranje procesa razvoja kroz poslovni plan. Uzimaju se u obzir razni interni i eksterni čimbenici, npr. vrijednost kupca, atraktivnost tržišta, razlike u potencijalu, usklađenost strategije, potrebna tehnološka struktura i resursi te ostalo.

Procesni inovacijski čimbenici

Najčešće se rezultati poslovnih aktivnosti mjere financijskim pokazateljima, no postoje i razni drugi pokazatelji nefinancijske prirode, izravni i neizravni, objektivni i subjektivni (Saunila, Ukko, 2012). Procesni inovacijski čimbenici odražavaju sustav upravljanja organizacijskim i inovacijskim procesima. Velika izloženost riziku, rijetko dostupni krediti, nedostatak kolaterala i veliki troškovi kočnica su za financiranje R&D-ja. Međutim, uza sva ograničenja, umjesto kontinuiranog ulaganja u R&D, poduzeća mogu ulagati u manje rizične projekte i „jeftinije” aktivnosti za generiranje inovacija posebno potičući pravilno upravljanje inovacijskim procesima i inovacijski menadžment koji odgovarajućim tehnikama, koristeći se i vanjskim znanjima, dovodi do potpunog iskorištavanja inovacijskih potencijala (Rammer *et al.*, 2009).

Sustavi i alati te njihova primjena važan su čimbenik u procesu inovacija (Bessant, Francis, 1997). Mjerenjem njihove učinkovitosti dobiva se odgovor na pitanje „Ima li poduzeće koristi od formalnih sustava i alata za potporu inovacija?” Većina autora usmjerena je na financijsko mjerenje ulaznih čimbenika, dok je manji naglasak na mjerenju drugih elemenata u kategoriji.

Među financijskim čimbenicima postoji nekoliko čimbenika utvrđivanja primjerenosti sredstava za inovacijski projekt. Istraživači su većinom usmjereni na istraživanje i razvoj (R&D) te razvoj novog proizvoda (*new product development* – NPD), a ne i na druge oblike i vrste inovacija, npr. inovacije procesa ili poslovnog modela. Veliko poduzeće može potrošiti veliki proračun na inovativne aktivnosti na ulaznoj strani, ali ne može i generirati potrebne inovacijske rezultate. Bez unutarnje analize inovacijskih procesa poduzeće ne može generirati znanja za poboljšanje upravljanja inovacijskim aktivnostima (Carayannis, Provan, 2008). Primjerice, među mjernim instrumentima slabo su zastupljena znanja i vještine pa samim time nema razvijenih mjernih instrumenata odgovarajućih razina sposobnosti zaposlenika (Adams *et al.*, 2006). Također, propusti koji se odnose na pretjerano oslanjanje na financijske mjere, a ne na procesne mjere mogu, primjerice, biti primjena financijskih mjera optimizacije portfelja, ali nedostatak mjera sposobnosti portfelja. Slično je i s oslanjanjem na kodificirano znanje, kao što su patenti, ne uključujući nematerijalne mjere, npr. prešutno znanje. Također, mjerenje razine resursa ili aktivnosti bez naznaka optimalne razine te mjerenje pokretača inovacija bez mjera o tome jesu li ti pokretači međusobno usklađeni te imaju li čvrstu strategiju. Nadalje, mjere prisutnosti kojima se ne mjeri kvaliteta (npr. upotreba dihotomnih (da/ne) mjera koje ne ukazuju na dobro djelovanje) ili mjere prisutnosti vodstva (ali ne i kvalitete vodstva). Općenito je zabilježena odsutnost mjera za važna svojstva organizacijskih struktura kao što je fleksibilnost te nedostatak mjera usklađenosti strukture i okoliša, tehnološka i NPD pristranost prema mjerama upravljanja projektom i relativna odsutnost mjera za uslužne sektore. Također je uočen manjak mjera unutarnje komunikacije te opći nedostatak mjera za upravljanje komercijalizacijom, osobito u području marketinga i prodaje inovativnih proizvoda i usluga. Sve ove praznine i neravnoteže trebale bi biti poticaj i usmjerenje za daljnja istraživanja s ciljem razvoja uravnoteženog skupa mjera koji pokriva sve poddimenzije ulaznih i procesnih čimbenika unutar domene inovacijskog menadžmenta.

Izlazni inovacijski čimbenici

Izlazni inovacijski pokazatelji obično mjere rezultate uspješnih inovacija i vrlo je teško kvantitativno prikazati sve vrste inovacija. Izlazni pokazatelji ne mjere ekonomsku vrijednost svih vrsta inovacija, a kada predstavljaju kratkoročnu realiziranu uspješnost inovacijske aktivnosti, uglavnom uključuju broj patenata, patentne citate, licencije poduzeća, broj novih

proizvoda ili usluga te postotak prodaje od inovacija (Michalisin, 2001; Tura *et al.*, 2008; Alpkan *et al.*, 2010). Izlazni inovacijski pokazatelji koji predstavljaju ostvareni dugoročni uspjeh inovativne aktivnosti mogu biti profitna marža ili tržišni udjel poduzeća, stopa rasta poduzeća, dominantan dizajn ili tehnološki standard, sljedeće inovacije koje proizlaze iz primarne inovacije, stupanj disrupcije itd. (Carayannis *et al.*, 2003). Problem izlaznih čimbenika jest u tome što su vrlo često prikladni samo za određene vrste inovacija i organizacija. Na primjer, nisu prikladni za mala ili uslužna poduzeća (Albaladejo, Romijn, 2000). U usporedbi s financijskim pokazateljima, nematerijalni su pokazatelji mnogo manje istraženi i mnogo nerazvijeniji. Brojčana vrijednost nije uvijek najbolja ili najvažnija korist ostvarena mjerenjem, mnogo je važnije primijetiti promjenu u rezultatima mjerenja (Yliherva, 2004). Na primjer, patenti ili patentne prijave ukazuju na neku vrstu tehnološkog napretka, ali patenti rijetko postaju opipljivi proizvodi. Zapravo, 90 do 95 % svih patenata nema nikakvu relevantnost na tržištu, a 99 % ne uspijeva ostvariti nikakvu dobit za poduzeće (Stevens, Burley, 1997). Ipak, patentiranje je nužno za održavanje konkurentске prednosti tako da je jasno da patenti ukazuju na inovativnost poduzeća.

Izlaznim inovacijskim čimbenicima ocjenjuju se i učinci inovacijske sposobnosti. Sposobnost se u ovom kontekstu odnosi na sposobnost poduzeća za obavljanjem koordiniranog seta zadataka, upotrebu resursa u svrhu postizanja određenog krajnjeg rezultata (Helfat, Peteraf, 2003, 999). Za mjerenje inovacijske sposobnosti poduzeća najvažnije je naći prave pokazatelje kojima bi se na najbolji mogući način izmjerio stupanj učinkovitosti pojedine inovacije. Razlike postoje u mjerenju industrijskih i tehnoloških inovacija u odnosu na uslužne koje se teže mjere i često nemaju odgovarajuće pokazatelje (Tura *et al.*, 2008). Inovacijska sposobnost najčešće se mjeri kroz industrijske i tehnološke inovacije, tj. nove proizvode, a neki autori spominju samo input i output mjere, odnosno dijele ih na tri pokazatelja: broj inovacija u trogodišnjem razdoblju, broj patenata i indeks značajnosti inovativnih outputa u trogodišnjem razdoblju (Albaladejo, Romijn, 2000). Prema Cavusgil *et al.* (2003), nekoliko studija proširuje broj pokazatelja na više od tri: učestalost inovacija, redoslijed ulaska na tržište, istovremeni ulazak na više tržišta te sposobnost osvajanja novih tržišta iskorištavanjem različitih aspekata inovacijskih sposobnosti.

2.5. Holistički pristup poznavanju utjecajnih čimbenika i njihova međusobna povezanost pri mjerenju rezultata inovacijskih procesa

Multidimenzionalni i holistički pristup mjerenju rezultata inovacijskog procesa ima značajnu potporu u znanstvenoj literaturi (Hagedoorn, Cloodt, 2003; Dewangan, Godse, 2014), no činjenica je da postoje i razlike u mišljenjima oko uključenih dimenzija. Kad je riječ o mjerenju rezultata inovacijskih procesa, uglavnom su uočena dva pristupa:

- prvi, koji se bavi pozitivnim i negativnim stranama pokazatelja
- drugi, kojim se nastoji optimizirati metrika kroz klastere.

U vezi s prvim pristupom, Denti (2011, 2013) je sumirao najučestalije inovacijske pokazatelje u literaturi s naglaskom na njihove prednosti i nedostatke. Kategorizirani su kao proizvodno-tehnološki, financijski i subjektivni pokazatelji. Proizvodno-tehnološki pokazatelji odnose se na aspekte inovacijskog procesa čiji je cilj transformirati nove ideje i tehnologiju u opipljive proizvode (robu ili usluge).

Tablica 5: Proizvodno-tehnološki pokazatelji

| Pokazatelj | Istraživanje | Glavne prednosti | Glavni nedostaci |
|---|-----------------------------|---|--|
| Novi proizvod ili poboljšanje proizvoda | Elenkov i Manev (2009) | Mjeri aktualnu primjenu | Nema garancije da su svi proizvodi uspješni |
| Patenti ili prijava patenta | Jung (2008) | Mjeri tehnološki napredak | Patenti se rijetko realiziraju |
| Citiranje patenta ⁵ | Makri i Scandura (2010) | Pokazatelj važnosti patenta | Vlastito citiranje svog patenta |
| Objava invencije ili prijedlog | Axtell <i>et al.</i> (2000) | Pokazatelj stupnja generiranja ideje | Ideje se rijetko realiziraju |
| Inovacijski proces | West <i>et al.</i> (2003) | Pokazatelj poboljšanja u procesima i metodama | Previše fokusiranja na procese jest „inovatorska dilema” |

Izvor: Prilagođeno prema Denti, L. (2013). Measuring Innovation part 1: Frequently Used Indicators, <http://www.innovationmanagement.se>, (preuzeto 20. 4. 2016.) prema Denti, L. (2011). Leadership and Innovation: How and When do Leaders Influence Innovation in R&D Teams? Sveučilište u Gothenburgu. Švedska

Financijsko-tržišni pokazatelji odnose se na bitne aspekte financijskog poslovanja, tj. na stjecanje prihoda od prodaje i troškove povezane s R&D aktivnostima.

⁵ U kontekstu zakona o patentima, citati se odnose na popis referencija za koje se vjeruje da su važne u ranijoj tehnici. Citati mogu biti ispitivačevi ili autorovi. Pridonose „sužavanju” originalne aplikacije. Ispitivač može citirati referencije iz tehničkih časopisa, udžbenika, priručnika i izvora.

Tablica 6: Financijsko-tržišni pokazatelji

| Pokazatelj | Istraživanje | Glavne prednosti | Glavni nedostaci |
|---|-------------------------------------|--------------------------------|---|
| Prihod od prodaje novih proizvoda / ukupna imovina | Czarnitzki i Kraft (2004) | Pokazatelj uspjeha na tržištu | Vrlo široko, ostali čimbenici utječu na mjeru |
| Prihod od prodaje novih proizvoda / troškovi R&D-ja | Gumusluoglu i Ilsev (2009) | Pokazatelj efikasnosti R&D-ja | Teško je utvrditi valjanu osnovicu |
| Ukupni R&D trošak | García-Morales <i>et al.</i> (2008) | Lako ga je dobiti | Ne pokazuje inovacijsku efikasnost |
| Broj djelatnika u R&D-ju | García-Morales <i>et al.</i> (2008) | Lako ga je dobiti | Ne pokazuje inovacijsku efikasnost |
| Ulazak na novo tržište | Elenkov i Manev (2009) | Pokazatelj radikalne inovacije | Ugrubo, uspije 60 % novih proizvoda |

Izvor: Prilagođeno prema Denti, L. (2013). Measuring Innovation part 1: Frequently Used Indicators, <http://www.innovationmanagement.se>, (preuzeto 20. 4. 2016.)

Mjerenje s pomoću kvantitativno izraženih pokazatelja može dovesti do krivog zaključka, posebno ako se radi o rizičnim inovacijama. Takve aktivnosti Martin (2012) naziva „tamnim inovacijama”, a mogu se odnositi na inkrementalne inovacije (poboljšanje u kvaliteti), aktivnosti koje uključuju malo formalnog R&D-ja, aktivnosti koje su rijetko patentirane, što se djelomično može izbjeći subjektivnom procjenom. U tablici 7 slijedi pregled subjektivnih pokazatelja.

Tablica 7: Subjektivni pokazatelji

| Pokazatelj | Istraživanje | Glavne prednosti | Glavni nedostaci |
|---|-----------------------------|--|---|
| Sklonost djelatnika prema inovativnosti | De Jong i Den Hartog (2010) | Fleksibilno, može se mjeriti bilo koja inovacijska aktivnost | Nedvojbena ne vodi do opipljivih rezultata |
| Timska inovativnost | Hurley i Hult (1998) | Fleksibilno, može se mjeriti bilo koja inovacijska aktivnost | Niska korelacija s brojem implementiranih inovacija |
| Organizacijska inovativnost | Chen <i>et al.</i> (2006) | Holistička procjena organizacije | Teško utvrditi valjanu osnovicu |

Izvor: Prilagođeno prema Denti, L. (2013). Measuring Innovation part 1: Frequently Used Indicators, <http://www.innovationmanagement.se>, (preuzeto 20. 4. 2016.)

Odabir pokazatelja specifičan je za svako poduzeće i ovisi o čitavu nizu čimbenika. Njihova važnost varira ovisno o tehnološkim rješenjima te o specifičnostima proizvoda koji se nude. Osim toga, R&D funkcija može se razlikovati ovisno o stupnju formalizacije koji utječe na stupanj u kojem se odvija „tamna inovacija”. Kvalitetnije informacije mogu se dobiti kombiniranjem kvantitativnih i kvalitativnih pokazatelja te individualnom procjenom.

Na temelju mnoštva literature istraživane prvenstveno kroz elektroničke podatke, Adams *et al.* (2006) došli su do spoznaje da, iako postoje područja koja se u istraživanjima preklapaju, ipak nijedan model ne pokriva sve dimenzije inovacijskog menadžmenta. To im je poslužilo kao podloga za razradu sintetiziranog i integrativnog okvira koji je obuhvatio sedam kategorija (inputi, menadžment znanja, strategija, organizacija i kultura, portfolio menadžment, projektni menadžment i komercijalizacija) te njihova pripadajuća područja mjerenja:

Tablica 8: Mjerenje područja inovacijskog menadžmenta

| Kategorija okvira | Područje mjerenja |
|--------------------------|---|
| Inputi | Ljudi Fizički i financijski resursi Alati |
| Menadžment znanja | Stvaranje ideje Repozitorij znanja Protok informacija |
| Strategija inovacija | Strateška orijentacija Strateško vođenje |
| Organizacija i kultura | Kultura Struktura |
| Upravljanje portfeljem | Ravnoteža rizika / povrata Primjena alata za optimizaciju |
| Projektni menadžment | Efikasnost projekta Alati Komunikacija Suradnja |
| Komercijalizacija | Istraživanje tržišta Testiranje tržišta Marketing i prodaja |

Izvor: Prilagođeno prema Adams, R, Bessant, J., & Phelps, R. (2006). Innovation management measurement: A review. *International Journals of management Reviews*, 8 (1), str. 26.

Inputi se uglavnom bave resursima inovacijskih aktivnosti i uključuju razne čimbenike, od financija, ljudskih i fizičkih resursa do generiranja ideja. Intenzitet istraživanja i razvoja (R&D) najčešće je primjenjivani opći input. Uobičajeno se izražava kao odnos između izdataka za istraživanje i razvoj ili broja zaposlenih u R&D-ju i nekog vida učinka (prihod, dobit). No izdaci za R&D samo su jedan vid izdataka i ne uvijek primjeren, pogotovo kada se radi o malim i srednjim poduzećima koja formalno uglavnom i nemaju takav odjel, a suštinski mogu imati inovacijskih sposobnosti. Izdatci su mjera koja se zbog svoje dostupnosti podataka izraženih u financijskoj kategoriji najčešće javljaju kao input, i to kao ukupni izdatci ili troškovi u postotku

u odnosu na prihod od prodaje ili ukupan prihod ili pak kao trošak po jedinici (proizvoda, patenta, odjela...). Ulazne veličine mogu se analizirati pojedinačno prije nego što se agregiraju, npr. izdatci za R&D sastoje se od troškova koji su vezani za ljude, opremu, sredstva, objekte i sl. te su u stvari „sirovina ili podražaji koje sustav prima i procesira” (Brown, Svenson, 1988). Ljudi se mjere kao broj djelatnika uključenih u inovacije i obično se izražavaju u apsolutnom broju ili relativno u odnosu na ukupan broj zaposlenih. Prostor i oprema fizička su kategorija koja uključuje čitav niz pojedinačnih sredstava, od zgrada do računala. Neiskorišteni kapaciteti mogu biti važan katalizator za inovacije i dati priliku za diverzifikaciju i poticanje kulture eksperimentiranja. Upotreba sustava alata može biti važna za potporu inovacijskim procesima (Bessant, Francis 1997; Cooper *et al.*, 2004). Može se zaključiti da se kod inputa i outputa kao mjere najčešće uzimaju one koje se kao financijske kategorije izražavaju vrijednosno, a da se manje primjenjuju kvalitativne kategorije kao što su vještina, znanje i sl. Jednako tako, većina mjera više je usmjerena R&D-ju i razvoju novog proizvoda (NPD) negoli ostalim formama inovacija (npr. procesne inovacije, inovacija poslovnog modela)

Znanje je kategorija koja sve više zaokuplja pozornost u razmatranju inovacija zadnjih dvadesetak godina i ima važnu ulogu u inovacijskom procesu (Hull *et al.*, 2000). Odnosi se na apsorpciju znanja, odnosno sposobnost poduzeća da stječe informacije i komunicira o idejama. U literaturi se najčešće spominju: stvaranje ideje, repozitorij znanja, koji uključuje implicitno i eksplicitno znanje, te prijenos znanja, što uključuje prikupljanje informacija i umrežavanje. Ideje su sirovina koju tek treba pretvoriti u inovaciju i zato neki autori to početno razdoblje nazivaju „fuzzy” (Moenaert *et al.* 1995; Kim, Wilemon 2002; Verworn 2002), a obuhvaća mogućnost za identifikacijom, analizu prilika, genezu i odabir ideje te koncept razvoja (Koen *et al.* 2001). Budući da je znanje osnova inovacije, treba postojati mogućnost da se to akumulirano znanje i mjeri kroz repozitorij znanja. Kombinacija novog i postojećeg znanja kroz protok informacija o eksternom i internom znanju čini osnovu ideje o apsorpcijskom kapacitetu, odnosno sposobnosti poduzeća da apsorbira i primjenjuje novo znanje, prepozna vrijednost novog vanjskog znanja, usvoji ga i na kraju komercijalizira. Visoka razina apsorpcijskog kapaciteta pozitivno utječe na inovacije i rezultate poslovanja (Tsai 2001; Chen 2004). No teško je predvidjeti što je „prava” razina ulaganja u apsorpcijski kapacitet za neko poduzeće, čime se dovodi u pitanje međunarodni benchmarking. Kvantitativni pristup najčešće uzima u obzir broj

patenata kao mjeru koja je kodificirana, no postoji i dio prešutnog znanja koje je teško mjeriti. Prijenos znanja može se mjeriti kroz povezanost grupe koja se bavi inovacijama s vanjskim organizacijama i izvorima, kroz prikupljanje informacija unutar poduzeća te kroz kontakt s kupcima i ostalim dionicima.

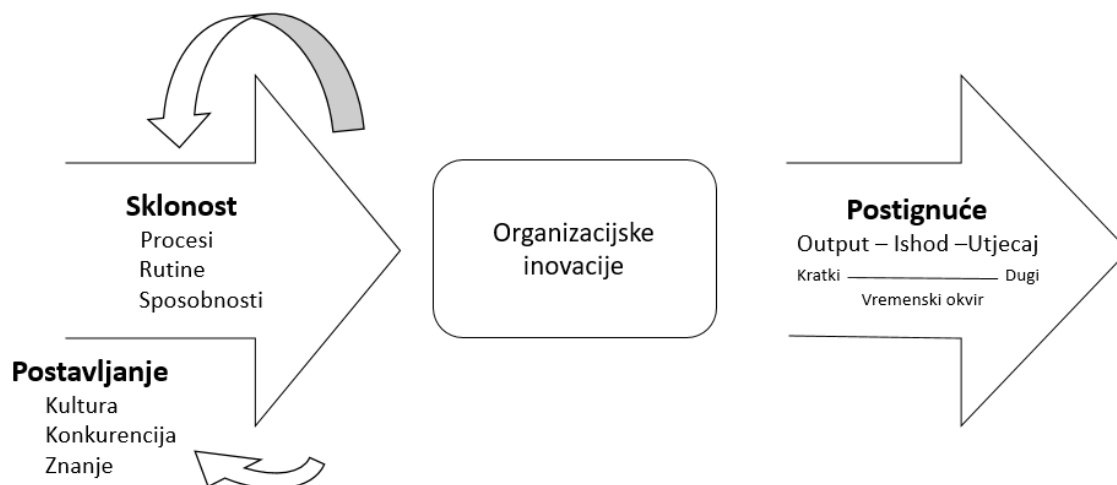
Inovacijska strategija podrazumijeva stav poduzeća u vezi s vlastitim konkurentskim okruženjem, a u pogledu novih proizvoda i tržišta. Uglavnom se primjenjuju pokazatelji o postojanju, vrsti i širini inovacijske strategije. Organizacijska kultura i struktura odnose se na način na koji su djelatnici grupirani i na to kakva je organizacijska kultura u kojoj djeluju. Jasno je da svaka organizacija stvara svoje specifično okruženje u kojem potiče ili ne potiče inovacije. Organizacijska i proizvodna fleksibilnost može se mjeriti stupnjem fleksibilnosti i odazivom na promjene. Fleksibilnost pojedinca može se mjeriti prilagodbom R&D osoblja na tehnološke promjene kao i željom za uvođenjem novih procedura i eksperimenata kojima bi se poboljšala situacija ili proces. U inovacijskom procesu važne su individualna i grupna autonomija te je stoga jedan od pokazatelja i stupanj slobode koju pojedinci imaju u svakodnevnom donošenju operativnih odluka. S moralnog i motivacijskog aspekta, inovativna organizacija može se mjeriti visinom nagrađivanja. Organizacijska kultura mjeri se jasnoćom iskazivanja misije i vizije koja olakšava inovativnost i omogućava fokusiran razvoj novih ideja koje se mogu preciznije procijeniti. Kvaliteta inovacije dijelom je funkcija vizije, ali i viša razina participativne sigurnosti olakšava inovativnost (West, 1990).

Upravljanje portfeljem važno je zbog brzine kojom se resursi upotrebljavaju u inovacijskom procesu i potrebe za njihovim upravljanjem. Učinkovitost kojom pojedino poduzeće upravlja portfeljem uvijek je ključna determinanta njegove konkurentске prednosti. Fokus upravljanja portfeljem na stvaranju je strateških, tehnoloških i resursnih mogućnosti koje upravljaju selekcijom projekta i budućim oblikom organizacije (Cooper *et al.* 1999). Isti autor naglašava da najbolji izvođači upotrebljavaju eksplicitno formalizirane alate i konzistentno ih primjenjuju na sve projekte koji pripadaju portfelju kako bi odgovorili na pitanje jesu li projekti na kratki ili dugi rok u ravnoteži i postoji li ravnoteža između velikih i malih te visokorizičnih i niskorizičnih projekata.

Projektni menadžment u kontekstu inovacija bavi se procesima koji pretvaraju inpute u tržišne inovacije. Inovacijski je proces složen i sastoji se od niza događaja i aktivnosti od kojih se neki mogu promatrati kao niz, a neki se javljaju istovremeno te je moguće da se inovacijski proces na nekom stupnju razlikuje na razini poduzeća ili unutar pojedinog projekta. Komunikacija je također važna i potvrđen je pozitivan odnos između interne komunikacije i inovacije koji se može mjeriti zajedničkim mehanizmima, npr. brojem odbora, brojem sastanaka i kontakata (Damanpour, 1991). Tranzicijska faza u kojoj se poduzeće sve manje oslanja na tehnološke sposobnosti može se smatrati komercijalizacijom. Komercijalizacijom se proizvod ili proces želi učiniti uspješnim, što podrazumijeva marketing, prodaju, distribuciju i zajedničke pothvate. Dok su tehničke mogućnosti važne u prvim fazama inovacijske aktivnosti, u fazi lansiranja i implementacije važne su marketinške sposobnosti. Pokazatelji se najčešće odnose na broj lansiranih proizvoda u određenom razdoblju. U okviru inovacijskog menadžmenta ovo područje i dalje treba razvijati jer sve prethodne faze, od ideje do lansiranja, neće rezultirati željenim outputom bez komercijalnog dijela.

Kritizirajući pojedinačne i limitirane skupine inovacijskih pokazatelja, Carayannis i Provanca (2008) definirali su kompozitni inovacijski indeks (*Composite Innovation Index – CII*) koji se temelji na ulaznim, procesnim i izlaznim inovacijskim čimbenicima. Autori predlažu mješavinu mjera smještenu u sklopu 3P okvira za organizacijsku inovaciju. Inovacija se pojavljuje uz pomoć triju kritičnih čimbenika na razini poduzeća, a to su: postavljanje (*Posture*), sklonost (*Propensity*) i postignuće (*Performance*). Sva tri čimbenika prikazana su na slici 5.

Slika 5: Kompozitni inovacijski indeks



Izvor: Prilagođeno prema Carayannis, E. G., & Provan, M. (2008). Measuring firm innovativeness: towards a composite innovation index built on firm innovative posture, propensity and performance attributes. *International Journal of Innovation and Regional Development*, 1(1), str. 94.

Prema Carayannis i Provan (2008), *Postavljanje* se odnosi na položaj poduzeća u sklopu većeg inovacijskog sustava u njegovu okruženju (regija, industrija, tehnološki intenzitet). *Postavljanje* posebice obuhvaća stupanj razvoja poduzeća duž triju dimenzija: organizacijske, tehnološke i tržišne (životni ciklus), što odražava spremnost poduzeća za uključanjem i uživanjem koristi od inovacija (Damanpour, 1991). Sadržaj triju dimenzija životnog ciklusa koje sadržava *Postavljanje* obuhvaća organizacijsku kulturu (za inovacije), konkurentsku poziciju i znanje (prvenstveno tehnološko i relacijsko). Poduzeće koje se svrstava u sva tri životnog ciklusa imat će bolji nadolazeći položaj u svojim inovativnim procesima i time će biti i bolje pozicionirano za ostvarenje pozitivnih rezultata inovacijskih aktivnosti. *Sklonost* je sposobnost poduzeća da iskoristi svoj položaj na temelju kulturološkog prihvaćanja inovacija. Na taj je način *Sklonost* nematerijalan odraz procesa, rutina i sposobnosti uspostavljenih unutar poduzeća. Poduzeće može imati odgovarajuće resurse, a time i veći eksternalizirani inovacijski status, ali može i imati nedovoljno razvijenu sposobnost inoviranja zbog kulturnih ili drugih ograničenja. *Postignuće* je trajan rezultat inovacija. Ovaj dio okvira obuhvaća tri razine: *izlazne pokazatelje (output), ishod i utjecaj*. *Izlazni pokazatelji* javljaju se kao neposredni, internalizirani rezultati inovacija. Rezultati inovacija mogu, na primjer, biti novo predstavljanje

proizvoda te patenti i licencije za prijenos tehnologija. *Ishod* uključuje rezultate srednjeg raspona, npr. prihode od novih proizvoda. Zaključno, *Utjecaji* predstavljaju trajnije, dugoročne prednosti koje poduzeće stječe inovacijskim kompetencijama, koje se odražavaju i na okruženje poduzeća. Status vrhunskog inovatora u industriji primjer je utjecaja *Postignuća* (Carayannis, Provan, 2008).

Unutar prakse upravljanja, mjerenje inovacijskog procesa ne treba shvatiti kao rutinu već se treba fokusirati na konkretne ulazne ili input, procesne i izlazne ili output pokazatelje. Izlazni pokazatelji se još uvijek u većem broju slučajeva oslanjaju na financijske kategorije dok su procesni pokazatelji, koji se osim kvantitativno izražavaju i kvalitativno (npr. optimizacija, prešutno znanje, usklađenost sa strategijom, kvaliteta vođenja, fleksibilnost, nedostatak mjera u uslužnom sektoru i dr.), manje zastupljeni, prvenstveno zbog teškoća u mjerenju. S tim u vezi, kako bi se olakšala apsorpcijska vrijednost rezultata istraživanja za gospodarstvo, Likar *et al.* (2011, 2014a) u svom *Referenčnom modelu inoviranja* nastoje na transparentniji način prikazati i klasificirati prepoznate inovacijske čimbenike i njihov utjecaj na rezultat poslovanja. Istraživanje se temelji na primarnim podacima periodičnog statističkog istraživanja inovacijske aktivnosti unutar prerađivačke industrije (NTP i VTP) te odabranih uslužnih djelatnosti, dopunjenih s podacima iz drugih nacionalnih baza podataka. Uz ulazne čimbenike inovacija, te izlazne tj. neizravne (inovacijski) rezultate i izravne (poslovni) rezultate, u istraživanju je fokus i na organizacijskim čimbenicima inovacija koji su analizirali na uzorku svih poduzeća (npr. strateški aspekti inovativnosti, organizacijske kulture i klime, podrška od nadređenih, planirano traženje dobrih praksi itd.). Model na temelju referentnih i inovacijski aktivnih poduzeća služi kao osnova za procjenu vlastite inovativne izvedbe i provedbu svih korektivnih mjera. Poduzeća mogu uspoređivati pojedinačne čimbenike prema preporukama modela, a mogu i pravilno reorganizirati svoju inovativnu aktivnost i time pridonijeti učinkovitijem upravljanju inovacijskim procesima. Strukturiran je da najprije da preporuke na razini svih poduzeća koje su uveli inovacije, a potom se detaljnije usredotočujući na inovacijsko vodeća poduzeća.

3. ANALIZA INOVACIJSKIH SPOSOBNOSTI PODUZEĆA

Uspješna inovacija skup je dobro organiziranih i dobro vođenih projekata koji na najučinkovitiji i najdjelotvorniji način dostižu ciljeve. Inovacija se može „dogoditi” samo ako organizacija posjeduje odgovarajuće „alate” kojima pospješuje sposobnost inoviranja, tj. ako posjeduje inovacijske sposobnosti te samim time čini čvrstu i zdravu organizaciju. U nedostatku inovacijskih sposobnosti, poduzeća iskazuju slabost pri upravljanju inovacijskim procesom, što može rezultirati mnogim zastojsima i promašajima u samoj inovaciji (Tidd, Bessant, 2009). Da bi poslovalo i opstalo, svako poduzeće mora imati neke specifične sposobnosti. Mnogi autori proučavali su sposobnosti upotrebom različitih obilježja kao što su ljudski resursi (Penrose, 1959; Barney, 1991), temeljne kompetencije (Prahalad, Hamel, 1990), posebne kompetencije (Selznick, 1957; Hitt, Ireland, 1985), rutine (Nelson, Winter, 1982) i specifične vještine (Richardson, 1972). Ipak, sva ta obilježja odnose se na suštinski istu stvar: specifične sposobnosti koje poduzeće stvara i strateški primjenjuje kako bi identificiralo tržišne niše koje će se ispuniti novom ponudom vrijednosti.

Inovacijski kapacitet kao važan čimbenik održive konkurentnosti poduzeća

Kao ekonomski, tehnički i socijalni entitet, poduzeće ima središnju ulogu u gospodarskom sustavu. Ono promiče tehnološke promjene i inovacije. Dok su akademska istraživanja tehnoloških sposobnosti poduzeća dovela do boljeg razumijevanja samog procesa tehničke promjene, i dalje ne postoji konsenzus o konačnoj definiciji inovacijskih sposobnosti. Jedino su poduzeća s kapacitetom za inoviranje sposobna odgovarati na stalne promjene te istraživati nove prilike na tržištu (Brown, Eisenhard, 1995). Hurley *et al.* (2005) razlikuju „inovativnost”, kao kulturnu spremnost poduzeća i uvažavanje inovacija, od „inovacijskog kapaciteta”, što je stupanj inovacija koje poduzeće zaista stvara ili usvaja. Ako se kao primjer uzmu dva poduzeća koja posluju i konkuriraju u istoj industriji i na istom tržištu, svaki pomak u cijeni strateških resursa dovodi do različita utjecaja na rezultat poduzeća te njihovih vrijednosti, ukazujući na različitost u odnosima među kapacitetima poduzeća. Inovacija može proizići iz jedne od komplementarnih mogućnosti. Iako su tehnološke inovacije najvidljiviji i najopipljiviji tip

inovacija, nisu sva poduzeća tehnološki inovativna. Vrlo često konkurentska prednost poduzeća ne proizlazi iz nove tehnologije, već se može pretpostaviti da ta prednost proizlazi iz operativnih, upravljačkih ili marketinških sposobnosti te se može prenijeti na produktivnost, profitabilnost i ostale pokazatelje uspješnosti. Slijedeći Teece *et al.* (1997), poduzeća koja su uspjela preustrojiti svoje kapacitete i organizacijske procese sposobna su inovirati, natjecati se i preživjeti na kompetitivnom globalnom tržištu. Od presudnog značaja za inovativnost poduzeća niske tehnološke razine jest organizacija inovacijskog procesa, tj. način „upotrebe” vlastita i vanjskog dostupnog znanja, rutine, prakse, struktura poduzeća, komunikacija i suradnja te pripadajuće kvalifikacije i struktura zaposlenika. Uspješna tehnološka inovacija ne ovisi samo o tehnološkoj sposobnosti nego i o drugim kritičnim sposobnostima u područjima proizvodnje, marketinga, organizacije, planiranja strategije, učenja i alokacije resursa (Guan *et al.*, 2006). Inovacijska sposobnost poduzeća odražava se u nizu pokazatelja i ne može se mjeriti jednom dimenzijom (Chiesa *et al.*, 1998; Guan, Ma, 2003). Istraživanje inovacijskih sposobnosti dovelo je do razvoja različitih teorijskih smjernica, npr. tehnoloških sposobnosti (Lall, 1992), marketinških sposobnosti (Kotabe *et al.*, 2002), apsorpcijskih sposobnosti (Cohen, Levintal, 1990), organizacijskih sposobnosti (Chandler, 1992), proizvodnih sposobnosti (Guan *et al.*, 2006), konfiguracijskih sposobnosti (Hirsch-Kreinsen, Bender, 2006), dinamičkih sposobnosti (Teece *et al.*, 1997) i mnogih drugih.

3.1. Apsorpcijski kapacitet

Ako je znanje od temeljne važnosti za inovacije, tada bi trebalo biti moguće i izmjeriti akumulirano znanje poduzeća, tj. njegovu „riznicu znanja”. Inovacije su povezane s kombinacijom novog i postojećeg znanja, unutarnjeg i vanjskog znanja te mehanizma s pomoću kojeg znanje cirkulira u poduzeću (Adams *et al.*, 2006). Ideje su glavni resurs i polazna točka svih inovacija. Formalni i neformalni sustavi generiranja ideja povećavaju broj i kvalitetu ideja. Velika poduzeća obično imaju šire tržište i veće tehnološko iskustvo te samim time kumulativna priroda učenja pomaže poboljšanju kvalitete ideja. Usto, širina vanjske mreže partnera potencira veću mogućnost sustavne aktivnosti ispitivanja novih tržišta i novih dostupnih tehnologija (Koc, Ceylan, 2007).

Vrlo važna komponenta inovacijskog kapaciteta jest sposobnost iskorištavanja vanjskog znanja te mogućnost njegova korištenja i procjene kao funkcija razine prethodno stečenih srodnih znanja. U osnovi, to predznanje uključuje osnovne vještine, ali također može uključivati i poznavanje najnovijih znanstvenih i tehnoloških dostignuća u danom polju. Stoga prethodno stečeno znanje utječe na sposobnost prepoznavanja vrijednosti novih informacija, asimilaciju te komercijalizaciju. Te sposobnosti zajedno tvore „kapacitet apsorpcije” poduzeća (Cohen, Levinthal, 1990). Prema Von Hippelu i Schraderu (1996), vanjske mreže utječu na inovacije poduzeća i vrlo su važan izvor za generiranje ideja. U vanjske mreže ubrojaju se sveučilišta, kupci, dobavljači i konkurenti na tržištu. Hoffman *et al.* (1998) podupiru ovaj nalaz i ukazuju na potrebu različitih i intenzivnih veza s vanjskim izvorima znanja, posebno za inovativna poduzeća, dok Kaufmann i Todtling (2000) naglašavaju da tu pretežno dominira odnos između kupca i dobavljača. Nadalje, O'Connor i McDermott (2004) tvrde da veliki doprinos inovativnosti pruža rad u okruženju velikih i etabliranih poduzeća s bogatim informacijskim mrežama dostupnima zaposlenicima. Tim se mrežama uspostavlja veza među bazama znanja te se ideje mogu učinkovito razmjenjivati.

Apsorpcijski kapacitet, tj. „sposobnost usvajanja” generira se na razne načine. Istraživanja pokazuju da su poduzeća koja sama provode R&D u boljoj poziciji u pogledu upotrebe eksterno dostupnih informacija. To upućuje na činjenicu da apsorpcijski kapacitet može biti stvoren kao nusprodukt investiranja jednog poduzeća u R&D. Također, apsorpcijski se kapacitet može razviti i kao nusprodukt proizvodnih procesa poduzeća. Abernathy (1978) i Rosenberg (1982) primijetili su da su poduzeća kroz izravno uključivanje u proizvodnju u stanju bolje prepoznati i iskoristiti nove informacije relevantne za određeno tržište proizvoda. Iskustvo u proizvodnji daje poduzećima potrebne temelje za prepoznavanje vrijednosti i implementaciju metoda za preustroj ili automatizaciju pojedinih proizvodnih procesa. Slanjem zaposlenika na napredne tehničke obuke poduzeća također izravno investiraju u svoj apsorpcijski kapacitet. Apsorpcijski kapacitet kao koncept najbolje se može razviti ispitivanjem kognitivnih⁶ struktura temeljenih na učenju (Cohen, Levinthal, 1990).

⁶ Kognitivna psihologija pokriva širok raspon područja istraživanja, istražujući pitanja o djelovanju percepcije, kreativnosti, pamćenja, pozornosti, predstavljanju znanja, mišljenju i rješavanju problema. Kognitivna psihologija radikalno se razlikuje od prethodnih psiholoških pristupa te pretpostavlja postojanje unutarnjih mentalnih stanja kao što su vjerovanja, želje i motivacija, za razliku od bihevioralne psihologije usmjerene na otkrivanje zakonitosti ponašanja ljudi u određenim situacijama, op.a.

3.2. Organizacijski kapacitet kao ključna determinanta razvijenosti

Organizacijske sposobnosti omogućavaju poduzeću da transformira inpute u outpute uz bolju efikasnost u odnosu na konkurentska poduzeća. Organizacijska inovacijska sposobnost odnosi se na sklad među odjelima, organizacijski odgovor na prilike, organizacijsku kulturu, mehanizam organizacije, metode upravljanja itd. (Guan et al., 2006). Naravno, sposobnosti poduzeća ovise i o karakteristikama samog poduzeća: strukturi radne snage i kapacitetima (vještine, odjeli), financijskoj strukturi, strategiji na tržištu, konkurenciji, strateškim savezima s drugim poduzećima ili sveučilištima te, iznad svega, unutarnjoj organizaciji. Mnogi su od ovih aspekata komplementarni, određena struktura vještina ide ruku pod ruku s određenom vrstom strategije, financijskom strukturom itd. (OECD, 2005). Prema Hirschu-Kreinsenu i Benderu (2006), konfiguracijske sposobnosti predstavljaju trajnu sposobnost poduzeća da sintetizira novosti stvaranjem novih konfiguracija znanja, artefakata i zaposlenika.

Prema Cohenu i Levinthalu (1990), apsorpcijski kapacitet organizacije ovisi o apsorpcijskom kapacitetu zaposlenika te iste organizacije. U tom smislu prethodna ulaganja u razvoj bitnih kapaciteta, kao što su pojedinačni kapaciteti zaposlenika, stvaraju temelje za sveukupan razvoj organizacijskog kapaciteta. Međutim, apsorpcijski kapacitet organizacije nije jednostavan zbroj apsorpcijskih kapaciteta njezinih zaposlenika i stoga je vrlo korisno razlučiti koji su aspekti „sposobnosti upijanja” iznimno organizacijski. Primjerice, inovativnost ovisi o organizacijskoj kulturi, konkretnije o stupnju organizacijske podrške. Mann (2005) tvrdi da se organizacijska potpora može podijeliti u tri oblika. Prvi pristup jest organizacijsko poticanje inovacija, tj. stupanj do kojeg istraživači osjećaju i percipiraju različite oblike potpore, npr. podršku idejama, povjerenje, emocionalnu sigurnost i mogućnost preuzimanja rizika. Drugi oblik odnosi se na pristup potrebnim resursima, prvenstveno vremenu, materijalima, stručnosti (*know-how*) i informacijama. Treći je oblik osnaživanje, tj. mjera u kojoj se istraživači osjećaju ohrabreni i doživljavaju slobodu pristupanja zadatku; drugim riječima, stupanj autonomije. Prisutnost tih vrijednosti i resursa može dovesti do stvarnog poboljšanja u inovacijskim rezultatima (Bain *et al.*, 2001). Na primjeru velikih slovenskih poduzeća Rozman i Stjepanović Vračar (2013) zaključili su da organizacija, tj. odnosi i interakcije među zaposlenicima utječu na kreativnost i inovacije. Kreativnost i inovacije uglavnom su pod utjecajem organizacijske kulture, timske

strukture, inovativnosti i menadžerske podrške zaposlenicima da djeluju na kreativan i inovativan način. Utjecaji drugih organizacijskih čimbenika imali su manju težinu ili nisu bili statistički značajni. Također, ustanovljen je jak utjecaj kreativnosti i inovacija na efikasnost (djelotvornost), ali manje na efektivnost (učinkovitost), što bi mogla biti posljedica činjenice da poduzeća uglavnom traže tehničke promjene i poboljšanja, a manje skrbe za financijske rezultate.

Nastavno na menadžersku podršku zaposlenicima, ekonomski uspjeh poduzeća niske tehnološke razine obično je povezan s profesionaliziranim menadžerima. Posao je menadžera optimizirati, racionalizirati i pojednostavniti procese svojih poduzeća duž danih smjernica kako bi se zadovoljile potrebe intenzivne cjenovne konkurencije na internacionaliziranim tržištima (Hirsch-Kreinsen, Schwinge, 2011). Menadžeri moraju donositi odluke koje odražavaju dvije vrste napetosti koje postoje u organizacijama: unutarnju orijentaciju nasuprot vanjskoj te potrebu za kontrolom u odnosu na potrebu za fleksibilnošću. Prema Deshpande *et al.* (1993) i Slater *et al.* (2014), iz ove dvodimenzionalnosti proizlaze četiri tipa kulture. *Fleksibilni „adhocracy”*⁷ tip hijerarhije karakterizira fleksibilnost i spremnost za preuzimanjem rizika, a vanjska orijentacija potiče poduzetnička i kreativna ponašanja. *Tržišni* tip razlikuje se po kontroli i vanjskoj orijentaciji koja potiče vrlo konkurentna ponašanja, uključujući agresivni razvoj proizvoda i programe širenja tržišta, intenzivnu izgradnju robne marke ili čak cjenovno natjecanje. *Klanski* tip primjer je fleksibilnosti i unutarnje orijentacije koja potiče ponašanja vezana uz uspostavljanje odnosa, kao što su usredotočenost na segmente vrijednosti svjesnih korisnika, pružanje vrhunske usluge korisnicima i upotrebu snažno podržane unutarnje prodajne snage. *Konačni* tip jest hijerarhija koju karakteriziraju kontrola i unutarnja orijentacija koja potiče ponašanja usmjerena na predvidljivost i „glatko” provedive operacije. Budući da je fleksibilna „adhokracijska” kultura obilježena vrijednostima poduzetništva, inovativnosti, prilagodljivosti, sklonosti riziku kao i vanjskoj orijentaciji, ta je vrsta kulture najbolji temelj za radikalnu sposobnost inovacija proizvoda (Slater *et al.*, 2011).

⁷ Organizacijska filozofija ili stil koji karakterizira adaptivno, kreativno i integrativno ponašanje koje je (za razliku od birokratskog stila) fleksibilno i neprekidno te stoga može brže reagirati na promjenjivo okruženje, op.a.

Pristup dinamičkih sposobnosti

Mnogi autori uz termin „sposobnost” vežu termin „rutina”, jedan od središnjih pojmova u teoriji evolucije (Nelson, Winter, 1982; Chandler, 1992; Peng *et al.*, 2007). Poduzeća ne posluju u savršeno stabilnim okruženjima da bi svoje rutine upotrebljavala na najučinkovitiji način. Budući da se konkurencija u okolini razvija, poduzeća moraju otkriti nove načine upotrebe svojih trenutačnih sposobnosti i rutina ili stvarati nove sposobnosti kroz inovacije. Pristup dinamičkih sposobnosti primjerice razjašnjava potrebu za stvaranjem, izgradnjom, izmjenama, prilagodbama, rekonfiguriranjem i ažuriranjem resursa i sposobnosti kako bi se odgovorilo na neprestano mijenjanje okoline i održavanje konkurentne prednosti (Teece *et al.*, 1997; Eisenhardt, Martin, 2000; Teece, 2007).

Dok se resurs definira kao „materijalni ili nematerijalni ulaz u proizvodnju koju poduzeće posjeduje, kontrolira ili ima pristup na određeno razdoblje”, sposobnost se definira kao „sposobnost organizacije da izvrši koordinirani skup zadataka, koristeći organizacijske resurse, radi postizanja određenog krajnjeg rezultata” (Helfat, Peteraf, 2003, 999). Za razliku od operativnih sposobnosti koje poduzeću omogućuju obavljanje svakodnevnih aktivnosti kao što su logistika, marketing i proizvodnja, dinamičke se sposobnosti konceptualiziraju kao mogućnosti višeg reda koje ne uključuju proizvodnju robe ili pružanje usluga. Dinamičkim kapacitetom definirana je sposobnost poduzeća da integrira, gradi i rekonfigurira unutarne i vanjske kompetencije potrebne za prilagođavanje brzomijenjajućem okruženju (Teece *et al.*, 1997, 516), tj. primarna funkcija dinamičnih sposobnosti jest omogućiti poduzeću da modificira svoje operativne sposobnosti radi poboljšanja učinkovitosti (npr. Teece *et al.*, 1997; Zahra *et al.*, 2006; Helfat, Winter, 2011; Piening, Salge 2015). Prema Teeceu (2007, 2009), dinamičkim kapacitetom obuhvaćene su tri razine sposobnosti. Prva je sposobnost osjećanja i oblikovanja prilika i prijetnji. Ovo je dimenzija sposobnosti inoviranja, tj. stvaranja novih ideja. Druga je sposobnost hvatanja prilike. Ona se odnosi na odabir novih ideja koje treba riješiti te kasnije razviti i ispuniti (upravljanje inovacijskim projektom). Posljednja je sposobnost preoblikovanja i upravljanja prijetnjama koja je povezana s održavanjem konkurentnosti kroz poboljšanje (kombinirajući i štiteći gdje je to potrebno) i rekonfiguraciju opipljivog poslovnog subjekta i nematerijalne imovine. Odnosi se na sposobnost poduzeća da se istraži i transformira te da se spasi od gašenja zbog ovisnosti o putanjama proteklog uspjeha. Međutim, postoje različitosti

među trima identificiranim sposobnostima. Menadžerske vještine potrebne za osjećanje prilike sasvim su različite od onih potrebnih za hvatanje prilike i onih potrebnih za preoblikovanje. Sve funkcije imaju zajednički poduzetnički kontekst, no uspješna poduzeća moraju naći način kako izgraditi i upotrijebiti sve tri sposobnosti, ponekad i istovremeno. Budući da se sve sposobnosti vjerojatno neće pronaći u jednom menadžeru, one moraju biti zastupljene unutar top menadžmenta, a izvršni direktor mora uspjeti u kreiranju timskog rada. Naravno, ako izvršni direktor ima dubinu u svim trima sposobnostima, poduzeće ima i veće šanse za uspjeh. Poduzeća s dobrim dinamičkim sposobnostima imaju poduzetničko upravljanje koje je strateško po prirodi i povećavat će vrijednost imovine unutar poduzeća te između poduzeća i drugih institucija u poslovnom ekosustavu (Teece, 2007).

Inovacija poslovnih modela

Koncept poslovnog modela postao je vrlo popularan u smislu konkurentskog uspjeha poduzeća. Da bi pothvat postao održiv, potreban je dobar poslovni model (Magretta, 2002), a svaki put kad poduzeće prihvati poslovni pothvat, ono eksplicitno ili implicitno primjenjuje određeni poslovni model (Teece, 2010). Jednostavno rečeno, poslovni model pojednostavnjen je i agregatan prikaz relevantnih aktivnosti tvrtke (Wirtz *et al.*, 2016), način na koji tvrtka strukturira vlastite aktivnosti (Onetti *et al.*, 2012), tj. priča koja objašnjava kako poduzeće radi (Magretta, 2002). Dizajniranje poslovnog modela i inovacije ključni su za uspješnost i uspjeh tvrtke (Zott, Amit, 2007; Zott *et al.*, 2011; Kesting, Günzel-Jensen, 2015).

Prošlo je vrijeme kada je inovirati značilo ulaganje poduzeća u vlastite velike istraživačke laboratorije, zapošljavanje najboljih ljudi koji su se mogli naći na tržištu, a onda strpljivo čekanje na nove proizvode. Troškovi stvaranja, razvoja i distribucije novih proizvoda strahovito su porasli, a životni vijek proizvoda sve je kraći, što znači da se čak i velike tehnologije više ne mogu oslanjati na mogućnost zarade zadovoljavajućeg profita u vremenu prije nego što proizvod izgubi jedinstvenost, brend i monopolističku poziciju. U današnje vrijeme inovacije moraju uključivati poslovne modele, a ne samo tehnologiju i R&D (Chesbrough, 2007).

U suvremenoj ekonomiji mnoga poduzeća shvaćaju dobrobiti modificiranja svojih proizvoda i procesa s ciljem održivosti. Inovacija poslovnog modela (*Business model innovation – BMI*)

jest koncept koji se vodi načelom da poduzeća inoviraju iskorištavanjem svojih resursa i svojih unutarnjih kapaciteta (Zott, Amit, 2010). Inovacija poslovnog modela ne zahtijeva nužno nabavu nove tehnologije ni stvaranje potpuno novih tržišta, već se može raditi o isporukama postojećih proizvoda proizvedenih postojećim tehnologijama na postojećim tržištima. Također, zbog čestog uključivanja promjene nevidljive vanjskom svijetu, inovacija poslovnog modela može donijeti prednosti koje je teško kopirati (Girotra, Netessine, 2014). Chesbrough (2010) je istaknuo da tehnološki napredak prisiljava organizacije na promjenu pa iz tog aspekta poslovni modeli moraju biti posebno osjetljivi na dinamiku industrije i cjelokupnog okruženja. U tom slučaju važnu ulogu ima stručni kadar za transfer tehnologije jer on mora transformirati znanstvene rezultate u utržive inovativne proizvode. Slijedom toga, organizacije koje kombiniraju i usvajaju poslovne modele s ciljem distribuiranja inovacija temeljenih na istraživanju mogu imati veću predispoziciju za uspjeh. Ipak, valja napomenuti da nisu svi poslovni modeli uspješni u jačanju inovacija, samo određeni vode do višeg stupnja inovativnosti.

3.3. Kapacitet strateškog planiranja i kontrole

Inovacija potiče sposobnost za identifikaciju mogućnosti i veza, sposobnost razlučivanja interakcije ili veze između dviju ili više (naizgled) izoliranih činjenica te na kraju i samo iskorištavanje. Ponekad je proces inovacije složeniji nego što se očekuje na početku, a kvaliteta i učinkovito upravljanje procesom povećat će mogućnosti uspjeha (Likar, 2013). Poduzeće ne određuje svoj strateški položaj samo procesima učenja, povezanošću svojih unutarnjih i vanjskih procesa te poticajima, već i pozicijom svoje poslovne imovine u bilo kojem trenutku u vremenu. Pod poslovnom imovinom poduzeća ne misli se samo na postrojenja i opremu (osim ako su specijalizirana), već se misli na imovinu u vidu znanja kojim je teško trgovati te imovinu poduzeća povezanu s ugledom i mrežom partnera. To će poduzeću odrediti tržišni udio i profitabilnost u bilo kojem trenutku u vremenu (Teece, Pisano, 1994). Analiza na uzorku od 847 prerađivačkih i uslužnih poduzeća i njihovih predsjednika uprave pokazala je da su ugled poduzeća, ugled proizvoda i „know-how” zaposlenika najvažniji za uspjeh poduzeća te su, zajedno s kulturom poduzeća i mrežom partnera, rangirani iznad specijaliziranih fizičkih resursa. Prema Hallu (1992), ugled poduzeća, ugled proizvoda i „know-how” zaposlenika također su prepoznati kao resursi za koje bi trebalo najduže vrijeme da se zamijene, čime se sugerira njihova važnost u održavanju prednosti. Ugled ili reputacija poduzeća uglavnom se gradi godinama na vrhunskim kompetencijama te je kao takva vrlo krhak resurs. Treba vremena da se stvori, ne može se kupiti i vrlo se brzo može izgubiti. Jedan od ključnih zadataka menadžmenta jest da u svakom zaposleniku dobije „promotora i skrbnika” ugleda organizacije u kojoj radi (Hall, 1992). Primjerice, „financijska mrkva” i „batina odgovornosti” jest model koji motivira zaposlenike da obavljaju uske, određene zadatke, ali općenito obeshrabruje ljude da prelaze zadani okvir. Kada je riječ o unutrašnjoj motivaciji zaposlenika, divljenje i pljesak neusporedivo su učinkovitiji stimulansi (Evans, Wolf, 2005). Članak Evansa i Wolfa (2005) slikovito to pojašnjava na primjeru razvojnih programera: „Osobni ugled razvojnog programera vezan je uz svako izdanje. Ako stvarate nešto što šaljete u svijet, nešto što milijunima korisnika predstavlja vašu filozofiju računanja, uvijek ćete to učiniti najboljim proizvodom koji možete.”

Pravilno definiran sustav pokazatelja uspješnosti koji potiče inovacije kroz sustav nagrađivanja potreban je svakom poduzeću koje želi poboljšati vlastiti inovacijski kapacitet. Izbor

pravog/pravilnog mjernog sustava sigurno nije jednostavan zadatak. Istraživanje koje su Andrew *et al.* (2009) proveli na 2 701 izvršnom direktoru pokazalo je da većina poduzeća (52 %) upotrebljava samo pet ili manje mjernih pokazatelja. Nasuprot tome, iskustvo je pokazalo da pravovremena reakcija i pravilno upravljanje inovacijskim procesom zahtijevaju od 10 do 12 mjernih pokazatelja uspješnosti (Andrew *et al.*, 2010). Chiesa *et al.* (1996) razvili su prvi sustavni model inovacijske revizije koji je često upotrebljavan za poticanje inovacije u mnogim zemljama. Ovaj model ispituje skup dobrih praksi upravljanja organizacijskim inovacijama kako bi utvrdio inovacijske sposobnosti poduzeća. Model se temelji na istraživanju „ključnih” procesa inovacija (nova generacija koncepata, razvoj novih proizvoda – NPD, redefiniranje procesa, nabava tehnologije) kao i drugih aktivnosti „podrške” (tržišni fokus, vodstvo i kultura, alokacija resursa, organizacijski sustavi). Važnost inovacija za održivost poduzeća utjecala je i na praksu kontrole. Kontroling kao podrška menadžmentu koja pruža transparentne informacije za proces donošenja odluka mora pratiti fokus i aktivnosti menadžmenta. Stoga kontrolori oblikuju i prate proces upravljanja inovacijama, pomažu u definiranju ideja, analiziraju implementaciju inovacija, korigiraju i prate učinke novih inovacija ili inovacija procesa. Obveza kontrolora jest odabrati odgovarajuće instrumente i prilagođene metrike za analizu učinkovitosti inovacija. Studija koju su na hrvatskim poduzećima proveli Vitezić i Vitezić (2015) potvrđuje još uvijek nedovoljnu uključenost kontrolora u sve faze inovacijskog procesa. Koordinativna i integrativna funkcija kontrolinga nije dovoljno iskazana u cijelom inovacijskom procesu. I dok je odjel kontrolinga uglavnom uključen u početnoj fazi kroz studiju izvodljivosti (feasibility studija) te kroz prateću analizu provedbe inovacije, funkcija kontrolinga trebala bi uključivati koordinaciju, planiranje, kontrolu i analizu u svim fazama upravljanja inovacijama.

Kreativnost i inovacije češće se pojavljuju u decentraliziranom i fleksibilnom nego u krutom organizacijskom kontekstu. Damanpour (1991) je identificirao dvije skupine strukturnih čimbenika koji određuju inovacijske sposobnosti u poduzećima. Prvo, visok stupanj specijalizacije, funkcionalna diferencijacija i profesionalnost utječu na inovacijske aktivnosti, što u konačnici pridonosi pojmu da poduzeća koja dijele rad na temelju stručnosti poticajno djeluju na inovacije. Drugo, važnost živahne unutarnje i vanjske komunikacije sugerira da strukture koje promiču animiranu, otvorenu i međusobno funkcionalnu komunikaciju pomažu

u poticanju inovacija. Nasuprot tome, strukture koje promiču centralizaciju i formalizaciju negativno su povezane s inovacijama (Damanpour, 1991). Izvršni direktori (CEO) i predsjednici uprava poduzeća, koji su u stanju istodobno se usredotočiti na vanjsko i unutarnje okruženje te na razvoj novih znanja i komercijalizaciju, učinkovitiji su vođe (Makri, Scandura, 2010). Prema studiji na visokotehnološkim poduzećima Makri i Scandura (2010) razvijaju dvije dimenzije vodstva i pokazuju da su učinkoviti prediktori inovacijske količine, kvalitete i novosti. Konceptija operativnog vodstva definira predsjednika uprave / izvršnog direktora koji ima vanjski fokus kada je u pitanju inovacija i koji je vješt u komunikaciji s vanjskim okruženjem i širenjem mogućnosti stvaranja novog znanja poduzeća. Konceptualizacija kreativnog vodstva naglašava predsjednika uprave / izvršnog direktora s fokusom na razvoj društvenog i ljudskog kapitala te na razvoj podržavajuće organizacijske kulture koja omogućava istraživanja i preuzimanje rizika. Zaključno, da bi se ideje i informacije mogle lakše dijeliti, poduzeće mora uspostaviti kreativno ozračje koje je u osnovi skup normi i društvenih pravila koji reguliraju ono što ljudi mogu raditi, a ponekad i misliti. Potenciranjem kreativnog ozračja poduzeće snažno doprinosi inovativnosti (Hunter *et al.*, 2007). Iako i operativna i kreativna vodstva imaju pozitivan učinak na količinu inovativnosti, kreativna su vodstva najvažnija za povećanje inovacijske novosti i kvalitete (Makri, Scandura, 2010).

U strateškom upravljanju inovacijama tehnološka strategija značajna je pretpostavka inovacijskog kapaciteta, a za velika poduzeća uobičajeno je da su im tehnološka strategija i tehnologija usklađene s poslovnim planovima i strategijom poduzeća (Koc, Ceylan, 2007).

Proces inovacije obično se izjednačava s neprestanim nastojanjem poduzeća da iskoristava nova i jedinstvena znanja (Nonaka, Takeuchi, 1995). Prema Cohenu i Levinthalu (1990), znanje poduzeća ne ovisi samo o internim aktivnostima učenja, već i o aktivnostima učenja raznih aktera izvan samog poduzeća. Međutim, neke druge vrste inovacijskih veza, npr. sa sveučilištima i istraživačkim centrima, možebitno zahtijevaju malo veću stručnost i sposobnost apsorpcije poduzeća. Također, veze sa sveučilištima i istraživačkim centrima rizične su zbog nesigurnosti komercijalne primjenjivosti rezultata istraživanja, što manjim poduzećima u odnosu na veća poduzeća, koja su bolje opremljena za iskorištavanje tih rizika, stvara problem zbog nedostatka resursa.

Intelektualni kapital

Sposobnost nekog poduzeća da inovira usko je povezana s njegovim intelektualnim kapitalom ili njegovom sposobnosti upotrebe resursa znanja (Subramaniam, Youndt, 2005). Iako do danas nema općeprihvaćene definicije ili klasifikacije intelektualnog kapitala (Canibano *et al.*, 2000; Bhartesh, Bandyopadhyay, 2005), suvremena literatura o upravljanju intelektualnim kapitalom naglašava važnost utjecaja „mekog” dijela organizacije (nematerijalna imovina kao što su kvalitete i sposobnosti zaposlenika i menadžera, dosadašnje iskustvo u inovativnim projektima, fleksibilnost menadžmenta, mreže s klijentima itd.) na inovacijske rezultate (Subramaniam, Youndt, 2005, Chen, Huang, 2009; Alpan *et al.*, 2010). Intelektualni kapital prepoznat je kao znanje koje se može pretvoriti u buduću dobit i obuhvaća razne resurse poput ideja, izuma, tehnologija, dizajna, procesa i softvera (Sullivan, 1999). Prema Riahiju-Belkaouiju (2003) i Youndtu *et al.* (2004), intelektualni se kapital upravo zbog svoje složenosti (teško se mijenja ili imitira) smatra strateškim resursom koji poduzeću omogućava stvaranje dodane vrijednosti. Prethodna istraživanja identificirala su tri istaknuta aspekta intelektualnog kapitala: ljudski, organizacijski i socijalni kapital (Subramaniam, Youndt, 2005). Ljudski kapital definira se kao znanje, vještine i sposobnosti koje žive i upotrebljavaju pojedinci (Schultz, 1961). Organizacijski kapital obuhvaća institucionalno znanje i šifrirano iskustvo koje se nalazi unutar poduzeća, a upotrebljava se kroz baze podataka, patente, priručnike, strukture, sustave i procese (Youndt *et al.*, 2004). Treći je aspekt socijalni ili društveni kapital i definira se kao znanje koje je ugrađeno, dostupno i upotrebljavano u međusobnim odnosima pojedinaca i njihovih mreža međusobnih odnosa (Nahapiet, Ghoshal, 1998).

Za razliku od intelektualnog vlasništva (Intellectual Property – IP) koje može biti zakonski zaštićeno (patentirano), intelektualni kapital kao nadpojam više je nematerijalan (npr. vlasnik IP-a mora napraviti potpunu objavu imovine) i obično nema vezan pravni oblik vlasništva. Intelektualni kapital nema datum isteka i uz pravilno upravljanje stvara dodanu vrijednost. Na primjeru irskih poduzeća prema Roper *et al.*, (2008) vidljivo je da kvaliteta ljudskih resursa, koja se manifestira kao sposobnost upotrebe znanja poduzeća, ima značajan utjecaj na lanac vrijednosti inovacija i to na tri načina. Prvo, iako imaju malo utjecaja na vanjske izvore znanja, kvalitetni ljudski resursi pospješuju unutarnji R&D te komplementarnim efektima pozitivno

utječu na druge aktivnosti povezane s izvorom znanja poduzeća. Drugo, visokokvalitetni ljudski resursi pozitivno pridonose sposobnosti transformacije znanja u inovacijske proizvodne funkcije te inovacije proizvoda i inovacije procesa. Treće, jaki i pozitivni koeficijenti u funkcijama rasta proizvodnje i produktivnosti ukazuju na to da razina vještina doprinosi sposobnosti poduzeća da stvara dodanu vrijednost od inovacija.

Dodana vrijednost intelektualnog kapitala smatra se razlikom između izlazne vrijednosti intelektualnog kapitala poduzeća i ulazne vrijednosti, tj. troškova intelektualnog kapitala poduzeća. Uzimajući u obzir sve veću važnost uloge intelektualnog kapitala u kreiranju vrijednosti, Pulic (1998, 2004) i kolege razvili su novu metodu za mjerenje intelektualnog kapitala poduzeća koju su nazvali „koeficijentom dodane vrijednosti intelektualnog kapitala” (VAIC). Ova je metoda vrlo važna jer omogućuje mjerenje doprinosa svakog resursa (ljudskog, strukturalnog, fizičkog i financijskog) u stvaranju dodane vrijednosti poduzeća. Izračun VAIC metode slijedi niz različitih koraka. Dodana vrijednost angažiranog ljudskog kapitala⁸ (Human Capital Value Added – HCVA) jest pokazatelj koji mjeri u kojem obujmu zaposlenici dodaju vrijednost poslovanju. Kada bi se formuli dodao inovacijski kontekst i kada bi se promatrala projektno, mogla bi izgledati ovako:

Dodana vrijednost angažiranog ljudskog kapitala u inovacije (HCVAI) = [Prihod od inovacija – (ukupni trošak inovacija – trošak zaposlenika angažiranih u inovacije)] / broj zaposlenika (puno radno vrijeme) angažiranih u inovacije

Povećavanjem intelektualnog kapitala osigurava se dugoročna održivost poduzeća koja nadilazi generiranje profita. Očito je da postoji jaka korelacija između intelektualnog kapitala i stvaranja vrijednosti koja se očituje u interakciji imovine, procesa, mreže partnera i stjecanja osnovnih kompetencija te, konačno, u samoj tržišnoj vrijednosti poduzeća.

⁸ Prema sustavu Saratoga Institute Workforce Diagnostic System (2002) (u Rau, Bye, 2003)

3.4. Proizvodni kapacitet

Dugo je već poznato da se proizvodne sposobnosti snažno povezuje s konkurentnim uspjehom na temelju vremena, fleksibilnosti, niske cijene i kvalitete proizvoda (Terjesen, *et al.*, 2011). Proizvodne sposobnosti temeljne su vještine u prerađivačkoj industriji i poduzećima omogućuju postizanje proizvodnih ciljeva koji uključuju područja kao što su dosljednost kvalitete proizvoda koji odgovara specifikacijama, kontrola troškova, brzina i protočnost proizvodnje, volumen i fleksibilnost proizvoda te pouzdanost isporuke (Swink, Hegarty, 1998; Boyer, Lewis, 2002; Sheather, 2002; Hanna, 2007). Razvijene proizvodne sposobnosti odavno su prepoznate kao izvor konkurentske prednosti i visokih rezultata poslovanja poduzeća (Skinner, 1969; Vickery *et al.*, 1993). Terjesen *et al.* (2011) u studiji na 106 poduzeća visoke tehnološke razine u Velikoj Britaniji empirijski su potvrdili pozitivan odnos između proizvodnih sposobnosti povezanih s niskom cijenom proizvodnje i kvalitetom proizvoda te poduzetničkih rezultata. Međutim, među mlađim je poduzećima posjedovanje jakih proizvodnih sposobnosti relativno rijetko (Lu, 2000; Ernkvist, 2008; Fan, 2009). To je često jer se proizvodne sposobnosti temelje na složenoj međuovisnosti resursa i organizacijske rutine koju je potrebno godinama razvijati (Hayes *et al.*, 1988; Cleveland *et al.*, 1989). Osim toga, mlađa poduzeća često oskudijevaju resursima, što može usporiti njihovo uspostavljanje tehnološkog procesa te stjecanje skupe tehnologije i ostale materijalne imovine na kojoj se proizvodne sposobnosti ponekad temelje (Bowen *et al.*, 1994; Terjesen, *et al.*, 2011).

U svojem su istraživanju Koc i Ceylan (2007) otkrili da za većinu inovativnih tvrtki veliku važnost imaju četiri osnovna prediktora, tj. pokazatelja na temelju kojih se može prognozirati: tehnološka strategija, kvaliteta ideja, generiranje ideja te nabava i iskorištavanje tehnologije. Ako poduzeća žele postati i ostati inovativnima, trebala bi posebnu pozornost obratiti varijablama koje se sastoje od tih prediktora. Tehnološka strategija pruža ravnotežu između poslovne strategije s jedne strane te proizvodnih resursa i tehnologije poduzeća s druge strane. Tehnološka strategija mora biti usklađena s poslovnom strategijom organizacije kako bi inovativne aktivnosti doprinijele poboljšanju konkurentskog položaja poduzeća (Koc, Ceylan, 2007). U usporedbi s malim poduzećima, velika poduzeća pri strateškom upravljanju inovacijama obično imaju dovoljno menadžerskih vještina te općenito obraćaju pozornost na tehnologiju kao stratešku varijablu (Pratali, 2003).

Tehnološka sposobnost poduzeća dijelom je ugrađena u radnu snagu kojom poduzeće raspolaže. Institucionalne osobine i vlastiti resursi u menadžmentu kao što su, primjerice, stručnjaci za planiranje, uvelike pomažu poduzećima pri lakšoj implementaciji i primjeni planova. Važnost tehničkih vještina sve se više podudara s vrijednostima umrežavanja i vještinama timskog rada. Kvalificirani zaposlenici ključni su preduvjet za inovativnu tvrtku. Bez kvalificiranih radnika poduzeće ne može svladati nove tehnologije, a kamoli ih inovirati. Osim istraživača, poduzeću su potrebni inženjeri koji mogu upravljati proizvodnim operacijama, prodavači koji se razumiju u tehnologiju koju prodaju te koji uz prodaju znaju i prenijeti povratnu informaciju u vidu prijedloga kupaca kao i generalni menadžeri svjesni tehnoloških problema (OECD, 2005).

Važne pretpostavke inovativnog kapaciteta jesu nabava i iskorištavanje tehnologije. Izvor tehnologije u poduzećima može biti ili u internim razvojnim aktivnostima / sposobnostima ili u nabavi tehnologija od vanjskih dobavljača. Kaufmann i Toling (2002) navode da bi velike tvrtke trebale imati potrebne vještine za usvajanje visokih tehnologija, napredni tehnički *know-how* te istraživačke sposobnosti, osobito kad je riječ o znanstvenim kompetencijama.

3.5. Informacijski i marketinški kapacitet

Sposobnosti povezane s marketingom utvrđene su kao važan resurs za tržišne organizacije (Day, 1990, 1994). Prema definiciji, marketing je područje upravljanja posvećeno prodaji i s njom povezanih ostalih aktivnosti. Marketing je veza između proizvodnje i profita koja najprikladnijim kanalima stručno preuzima proizvode i usluge te pronalazi ljude spremne da ih kupe. Song *et al.* (2005, 2007) i Guan *et al.* (2006) navode da je marketinški kapacitet sposobnost poduzeća da prihvati inovacije, da promovira i prodaje proizvode na temelju razumijevanja potreba potrošača, pozicije konkurencije te troškova i koristi. Da bi se taj cilj ispunio, ključna je sposobnost razumijevanja tržišta. To podrazumijeva usko proučavanje ponašanja i načina života kupca, a sve u cilju razvijanja proizvoda ili usluge na najbolji mogući način, od svrhe, funkcije, kvalitete i izgleda do brzine kojom se isporučuje, mjesta prodaje, cijene i razine podrške pružene korisnicima. Kupci su vrlo čest i efikasan izvor inovativnih inputa, a brze promjene u preferencijama potrošača prilika su za rast, razvoj i inovacije. Iako je inovacija uspješno komercijalizirana invencija, nije na autorima i vlasnicima nove ideje, proizvoda, procesa, organizacijske ili marketinške inovacije da odlučuju koja je od tih inovacija

uspješna, već je ta odluka na kupcima (Mulej, 2005). Vanjski odnosi (partnerstva, outsourcing, podugovaranja) omogućavaju poduzećima pristup vanjskom znanju, a veze unutar lanca opskrbe (korisnici i dobavljači) imaju pozitivan učinak na inovacijske rezultate. Rezultati istraživanja koje su proveli Heidenreich (2009) i Hervas-Oliver *et al.*, (2011) potvrđuju da su dobavljači najvažniji izvor informacija i znanja za poduzeća niske i srednje niske tehnološke razine.

Empirijski dokazi potvrđuju pozitivan utjecaj marketinških sposobnosti na uspješnost poduzeća (Song *et al.*, 2005, 2007). Nath *et al.* (2010) u svojoj studiji na 102 logistička poduzeća u Velikoj Britaniji te Dutta *et al.* (1999) na 72 prerađivačka poduzeća otkrili su značajan pozitivan odnos između marketinških sposobnosti i uspješnosti poslovanja poduzeća. Međutim, prerađivačka poduzeća moraju se suočiti i s određenim izazovima u budućnosti. Zahtjevi potrošača stimuliraju brže i učestalije inoviranje proizvoda i usluga te naglašavaju važnost ulaganja u nove tehnologije u svim industrijama. Učestalo mijenjanje potrošačkih stavova prema proizvodima i robnim markama kao i velika rascjepkanost tržišta te nastavak sporog ili negativnog rasta u raspoloživom dohotku potrošača predstavljaju neke od ključnih izazova za industriju. U recesiji su potrošači postali skloniji kupovini na rasprodajama te kupovini u raznim diskontima i *outletima*. Također danas je vrlo teško ignorirati, primjerice iz perspektive prehrambene industrije, rastući tržišni udio privatnih marki zbog kojih su prerađivačka poduzeća postala sama sebi konkurencija na policama, naravno uz mnogo manju maržu na proizvodima privatnih marki. Trendovi se brzo mijenjaju, traži se raznolikost i autentičnost, potražuje se sve veći broj brendova, veličina, materijala, pakiranja, okusa, mirisa. Poduzeća moraju pronaći odgovore te tražiti put do kupaca u smislu inoviranja distribucije proizvoda i same komunikacije s kupcima. Još 1989. godine u svojoj je knjizi „The Eternally Successful Organization, The Art of Corporate Wellness” Philip B. Crosby naglasio važnost predviđanja budućih preferencija kupaca kao jednu od karakteristika suvremenog i vječno uspješnog poduzeća (Crosby, 1990, 12 – 13).

3.6. Istraživačko-razvojni (R&D) kapacitet

Poduzeća koja inoviraju i poduzeća koja kreću s inovacijskom aktivnošću suočavaju se s dvjema vrlo važnim odlukama. Prvo, koliko uložiti u istraživanje i razvoj. Drugo, kako izvršiti tu

investiciju. Značajan broj autora pokušao je odgovoriti na prvu od tih odluka, vezu između ulaznih R&D pokazatelja i inovacijskih rezultata koji se razmatraju u smislu inovacijske proizvodne funkcije (npr. Geroski, 1990; Love, Roper, 1999; Roper *et al.*, 2008), dok je drugi važan aspekt odluke o istraživanju i razvoju, hoće li se R&D provesti unutar poduzeća ili će se financirati provođenje R&D-ja izvan poduzeća, manje istraživano (Love, Roper, 2002).

Istraživanje i razvoj unutar poduzeća ili „in-house R&D” imaju ključnu ulogu u sposobnosti poduzeća da stvara nova znanja koja mogu poslužiti kao temelj za poticanje intelektualnog vlasništva i inovacija. U širem smislu, na temelju istraživanja o odrednicama inovacija, istraživačko-razvojna sposobnost poduzeća gotovo je uvijek snažno i pozitivno povezana s izlaznim inovacijskim čimbenicima, uz napomenu da je taj odnos snažniji u R&D intenzivnijim industrijama. Međutim, čak i u proizvodnim i uslužnim sektorima niske tehnološke razine, gdje je intenzitet R&D-ja na nižoj razini, dokazi upućuju na pozitivan odnos između inovacija i istraživanja i razvoja. Na primjeru prerađivačkih poduzeća Irske i Sjeverne Irske Roper *et al.* (2008) naglašavaju da unutarnji R&D i izvori znanja izravno pozitivno utječu na inovacije proizvoda i procesa te imaju pozitivne komplementarne učinke na ostale izvore znanja u poduzeću. Stoga se dva glavna mehanizma smatraju važnima u ovom odnosu: prvo, R&D može stvoriti nova znanja koja pružaju temelj za inovacije; drugo, stručni R&D kadar može povećati apsorpcijski kapacitet poduzeća, tj. njegovu sposobnost procjene, pristupa i apsorpcije vanjskog znanja (Love, Roper, 2015).

Berry i Taggart (1998) utvrdili su da poduzeća koja imaju R&D plan također naglašavaju veliku važnost aspekta poslovnog planiranja i oblikovanja strategije u formalnom smislu. Usto, takva poduzeća uključuju svoje zaposlenike zaposlene na poslovima istraživanja i razvoja u formuliranje strategije poduzeća i procjenu procesa te ovu aktivnost smatraju jednim od ključnih dijelova svojih korporativnih aktivnosti. Podržavajući ovo gledište, Lyne (2003) navodi da je osiguravanje uključenja jedinstvene perspektive R&D organizacije u korporativni proces strateškog planiranja često velik izazov, ali i ključan za poduzeće koje se suočava s novim i nadolazećim tehnologijama.

Poduzeća s relativno visokim tržišnim udjelima, koja posluju u koncentriranim industrijskim sektorima, vjerojatnije će održavati unutarnju sposobnost istraživanja i razvoja. Posebno je to

naglašeno ako ne postoji značajnija razlika u veličini poduzeća, što implicira na intenzivnije rivalstvo. To je u skladu s hipotezom da poduzeća koja posluju u prethodno navedenim uvjetima posebnu pozornost obraćaju na zaštitu imovinskih prava koja proizlaze iz njihovih istraživanja, a koja bi se inače mogla raspršiti gdje god se suradnja primjenjuje. Specifičnosti u fizičkom i ljudskom kapitalu također utječu na trošak jedinice, ali nemaju jasan utjecaj na izbor načina istraživanja i razvoja (Love, Roper, 2002).

Promicanjem istraživanja i inovacija usmjerenih na potrebe poduzeća te ubrzanjem razvoja novih tehnologija koje će u budućnosti omogućiti lakše poslovanje i gospodarski rast planira se zadržati (i povećati) položaj Europske unije u prerađivačkoj industriji. Poseban je cilj istraživanja i inovacija u području *budućih tehnologija i onih u nastajanju* (FET)⁹. Očekuje se da će aktivnosti FET-a pokrenuti radikalno nove linije tehnologije kroz neistražene suradnje između naprednih multidisciplinarnih znanosti i najsuvremenijih tehnologija. To će pomoći Europi da rano preuzme upravljanje obećavajućim budućim tehnološkim područjima koja zasigurno mogu obnoviti temelje za buduću europsku konkurentnost i rast. (www.ec.europa.eu, 29. 5. 2016.)

Kako bi preživjela i ostala konkurentna, poduzeća se moraju prilagoditi tehnološkim promjenama i novim znanjima. Iako su poduzeća niske tehnološke razine većinom R&D manje intenzivna, ona bi trebala znati postići ravnotežu između temeljnih i primijenjenih istraživanja s ciljem rješavanja značajnih pitanja i uspješnih pronalazaka rješenja. Jedan od načina jest stvaranje strateških saveza s drugim poduzećima u području istraživanja i razvoja. Povezivanjem s vanjskim partnerima poduzeća mogu postati inovativnija te u konačnici poboljšati svoje poslovanje. Međutim, uspjeh ovisi i o sposobnosti poduzeća da apsorbira i primjenjuje znanja stvorena kroz savez. Kada poduzeća steknu više iskustva u vanjskim istraživačko-razvojnim savezima, ona često postaju uspješnija u ostvarivanju koristi od samih saveza. To se naziva „organizacijskim učenjem” i često utječe na poboljšane poslovne rezultate.

⁹ Pod Obzor 2020, akcijama FET-a dodijeljen je privremeni proračun u iznosu od 2 696 milijuna eura.

4. EMPIRIJSKO ISTRAŽIVANJE INOVACIJA KOD PODUZEĆA S NISKOM I SREDNJE NISKOM TEHNOLOŠKOM RAZINOM (NTP)

4.1. Teorijska ishodišta za empirijsko istraživanje

Razdoblje recesije

Za razliku od faze ekonomske ekspanzije kada i neefikasni igrači mogu preživjeti, pa čak i rasti, gospodarski pad ili recesija¹⁰ ima tendenciju „izbacivanja” manje učinkovitih tržišnih igrača (Fingleton, 2009). Jedan od izlaza leži u inovacijama koje, bez sumnje, potiču gospodarski razvoj. Jasno se ispostavilo da, s obzirom na ulaganja u inovacije, kriza nije bila jednaka u svim europskim zemljama. Filippetti i Archibugi (2011) pokazali su da je kriza najviše negativno pogodila nove europske države članice slabijih nacionalnih sustava inovacija (National Systems of Innovation, NSI) koje su zaostajale tijekom razdoblja 2006. – 2008. Nasuprot tim rezultatima, Moore i Mirzaei (2016) utvrdili su da su zemlje s niskim i srednje niskim dohotcima manje izložene u vrijeme krize. Jedno od važnijih istraživanja koje su proveli Filippetti i Archibugi (2010) u europskim zemljama ukazuje na to da se oko 65 posto poduzeća deklariralo da će zadržati razinu ulaganja u inovacijske aktivnosti. Međutim, istraživanja u zemljama OECD-a potvrđuje da su izdatci za istraživanje i razvoj, zajedno s drugim rizičnim poslovima, među prvima koji će se „rezati” tijekom recesijskog razdoblja. Rezultati istraživanja koje su proveli Pellens *et al.* (2016) potvrđuju da su financijska i ekonomska kriza 2008./2009. kao i spor oporavak mnogih država ozbiljno i trajno utjecali na sposobnosti vlada da ulažu u istraživanje i razvoj.

Izdatci za istraživanje i razvoj (R&D) jedan su od najčešće upotrebljivanih pokazatelja inovacijskih aktivnosti poduzeća i zemalja, izravno povezan s inovacijama putem novih proizvoda i novih procesa, a neizravno kroz ulaganje u znanje. Za područje OECD-a u cjelini tijekom poslovnog ciklusa R&D izdatci pokazuju tendenciju veće varijacije od samog bruto domaćeg proizvoda (BDP). To sugerira da će očekivani pad BDP-a zbog gospodarske krize

¹⁰ Jedno nacionalno gospodarstvo u recesiji je ako u dva susjedna kvartala stagnira (takozvana „nulta stopa rasta”) ili bilježi negativan gospodarski rast.


rezultirati još većim smanjenjem izdataka za istraživanje i razvoj te će to smanjenje na neke zemlje vjerojatno utjecati više nego na ostale. Primjerice, tijekom razdoblja 1981. – 2007. najviše osjetljivosti istraživanja i razvoja na poslovne cikluse bile su u Mađarskoj, Slovačkoj, Poljskoj i Španjolskoj gdje je u prosjeku svaka varijacija u BDP-u povezana s varijacijom dva do tri puta većom u samom R&D-ju. U Danskoj, Japanu i Sjedinjenim Američkim Državama izdatci za istraživanje i razvoj kretali su se skoro srazmjerno BDP-u, dok su najmanje varijacije tijekom poslovnih ciklusa bile u Belgiji, Njemačkoj, Austriji, Norveškoj i Ujedinjenom Kraljevstvu (OECD, 2009).

Iako doprinos uslužnog sektora postaje očigledan, prerađivačka industrija i dalje djeluje kao motor rasta, osobito u zemljama u razvoju (Szirmai, 2012). Postoji pozitivan učinak prerađivačkog sektora na rast zemalja u razvoju s visokoobrazovanom radnom snagom, iako se čini da je od 1990. godine pozitivan utjecaj na rast samo u onim zemljama s nižom razinom BDP-a po stanovniku, što ukazuje na potrebu za snažnijom ulogom ljudskog kapitala kako bi se postigao jednaki pozitivni marginalni učinak (Szirmai i Verspagen, 2015). Nedavno su Bottazzi *et al.* (2014) i Duschl i Peng (2015) istaknuli razlike u stopama rasta proizvodnje na temelju konteksta i/ili karakteristika poduzeća. Bottazzi *et al.* (2014) utvrdili su da financijska ograničenja imaju snažan negativan utjecaj na distribuciju proizvodnih stopa prerađivačke industrije u Italiji. S druge strane, Duschl i Peng (2015) na kineskom su primjeru istaknuli da su distribucije stope rasta prerađivačkih poduzeća bile različite ovisno o vlasničkom statusu poduzeća. Treba naglasiti da je većina studija o distribuciji stope rasta provedena u razdobljima gospodarskog napretka, a samo mali broj u razdoblju ekonomske recesije (Perić, Vitezić, 2016). Recesija je intrigantna tema istraživanja iz nekoliko razloga. Christiano *et al.* (2015) navode da je najveći dio kretanja agregirane realne gospodarske aktivnosti tijekom Velike recesije zbog financijskih prijeloma, što je dovelo do pada proizvodnje, ulaganja i potrošnje. Odawa i Tanaka (2013) naglašavaju potražnju, opskrbu i financijske šokove tijekom recesije, dok Knudsen i Lien (2014) ističu smanjenje potražnje kao ključnu recesijsku karakteristiku koja uzrokuje lošije investicijske prilike zbog nižih očekivanih zarada. Zajedno sa slabijom dostupnošću kredita, razdoblje recesije može dovesti do nižih ulaganja, posebno onih poduzeća koja nemaju dovoljno internih sredstava (Knudsen, Lien, 2014). Gilchrist i Sim (2007) procjenjuju da je pad investicija tijekom recesije zbog financijskih ograničenja unutar intervala od 50 % do 80 %. Budući da se

prerađivački sektori na temelju izdvajanja za istraživanje i razvoj mogu svrstati u sektore visoke, srednje visoke, srednje niske i niske tehnologije (OECD, 2005), zanimljivo je analizirati ponašanje poduzeća, tj. njihovu inovacijsku aktivnost i pokazatelje uspješnosti poslovanja tijekom recesije. Pad proizvodnje tijekom recesije u visokotehnološkim prerađivačkim sektorima bio je upola manji nego u ukupnoj industriji (Jaegers *et al.*, 2013). U skladu s time, čini se da je kriza mnogo jače utjecala na prerađivačka poduzeća niske tehnološke razine u odnosu na njihove konkurente iz visokotehnoloških sektora (Caloghirou *et al.*, 2014).

Svjetska ekonomska kriza negativno je utjecala na vrijednosti, tj. obujam trgovine prerađivačke industrije zemalja OECD-a. Kada se govori o tehnološkoj intenzivnosti, od druge polovice 1990-ih do sredine 2000-ih vrijednost prerađivačke trgovine OECD-a većinom je bila određena trgovinom prerađivačkih poduzeća visoke tehnološke razine. Međutim 2005. godine trgovina prerađivača visoke tehnologije u OECD-u počela je padati i došla je do razine trgovine prerađivača srednje visokih tehnologija. Istodobno, trgovina prerađivača srednje niske tehnološke razine oštro je porasla, što se dijelom može pripisati povećanju cijena nafte, naftnih derivata i metala, posebno onih koje su potrebni za proizvodnju ICT proizvoda (OECD, 2011). Na slici 6 može se vidjeti trgovina zemalja OECD-a u razdoblju 1995. – 2009. podijeljenih po tehnološkoj intenzivnosti.

Slika 6: Trgovina zemalja OECD-a podijeljena po tehnološkoj intenzivnosti



Izvor: OECD (2011). Science, Technology and Industry Scoreboard

Pretpostavljalo se da će u procesu obnove nakon recesijskog razdoblja vodeću ulogu imati prerađivačka industrija (Pisano, Shih, 2009). Međutim, Pisano i Shih (2009) tvrde da naglasak nije bio na prerađivačkoj industriji u cjelini, već na specifičnoj potkategoriji prerađivača, točnije visokotehnološkoj tj. *high-tech* industriji. Prema Hatzichronoglu (1996), visokotehnološka poduzeća više inoviraju i osvajaju nova tržišta produktivnije upotrebljavajući resurse te općenito nudeći veću naknadu zaposlenicima. U skladu s tom tvrdnjom, iz perspektive politike Europske unije (Europska komisija, 2008, 2010), promicanje visokotehnoloških industrija kroz ulaganja u istraživanje i razvoj (R&D) smatra se ključnim za osiguranje konkurentnosti prerađivačke industrije. Međutim, takvo razmišljanje u pitanje dovodi sve brojnija literatura o razvoju niskotehnoloških proizvodnih procesa u kojoj se naglašava da neinvazivne industrije, poput prerađivačke industrije niske i srednje niske tehnološke razine, održavaju većinu gospodarskih aktivnosti te su kao takve iznimno važne u europskim zemljama (Hansen, Winther, 2011; Hirsch-Kreinsen, 2008; Kaloudis *et al.*, 2005). Primjerice, prije ekonomske krize 2008. godine poduzeća niske tehnološke razine pridonijela su s približno 55 posto dodane vrijednosti ukupne proizvodnje u EU-25 (Europska komisija, 2011).

Razine učinkovitosti visokotehnoloških sektora i sektora niske tehnologije međusobno su vrlo povezane. Niskotehnološki (*low-tech*) sektori postaju prilično tehnološki intenzivni jer su u

procesu proizvodnje oni značajni korisnici izlaznom tehnologijom, tj. proizvodima *high-tech* industrije (Hirsch-Kreisnen, Bender, 2006; Hansen, Winther, 2011; Czarnitzki, Thorwarth, 2012). Također, jasno je da tvrtke iz *low-tech* sektora ne čekaju pasivno da ih nadjačaju poduzeća iz zemalja s nižih troškovima proizvodnje, već upotrebljavaju različite strategije kako bi ostale konkurentne (Hirsch-Kreisnen, 2008). Štoviše, radno intenzivna *low-tech* poduzeća postupno se zamjenjuju poduzećima niske tehnološke intenzivnosti koja su usredotočena na povećanje ulaganja u visokokvalificiranu radnu snagu, napredne strojeve, pa čak i u istraživanje i razvoj. Implementacija novih tehnologija, zajedno s inkrementalnim inovacijama te fokusom na tržišne niše s višom dodanom vrijednosti, postala je ključna strateška odrednica niskotehnoloških poduzeća (Hansen, Winther, 2014).

Ipak, postoji još mnogo ograničavajućih čimbenika. Pitanje je sastoji li se još uvijek jezgra tradicionalnih prerađivačkih sektora od općenito malih poduzeća kojima dominiraju dobavljači? Kao što tvrdi Pavitt (1984), takva poduzeća okarakterizirana su zastarjelim procesnim tehnologijama sa slabim *in-house* R&D-jem (unutarnjim, tj. vlastitim aktivnostima istraživanja i razvoja) i inženjerskim sposobnostima. Protogerou *et al.* (2013.) smatraju da su tržišta niske tehnološke intenzivnosti općenito zastarjela i sporo rastuća te da je jaka cjenovna konkurencija natjerala poduzeća da se usredotoče na nadogradnju tehnologije i poboljšanje procesa, a ne na inovativne projekte. Slijedom toga, sektori i poduzeća na tržištima niske tehnološke razine imaju poteškoće u plasmanu „ekstremnih noviteta” jer su njihova tehnološka znanja i vještine uvelike zasnovani na dobro uspostavljenim, tj. već poznatim tehnološkim putevima (Hirsch-Kreisnen, Schwinge, 2011). Budući da tijekom recesijskog razdoblja vanjski resursi postaju oskudni i ograničeni, tvrtke su prisiljene oslanjati se na unutarnje sposobnosti i strateške rezerve. Dakle, ako inovacije procesa doista preoblikuju unutarnje sposobnosti poduzeća (koje su obično koncentrirane u *high-tech* industriji), onda bi bilo zanimljivo vidjeti ekonomske učinke ove transformacije na poduzeća niske tehnološke razine tijekom razdoblja gospodarskog pada.

4.2. Poduzeća s niskom razinom inovativnosti – prerađivačka HR NTP

Prerađivačka industrija sektor je gospodarstva s najvećim udjelom u strukturi bruto domaćeg proizvoda (BDP-a) i ukupnoj zaposlenosti Republike Hrvatske (cca 30 %) te apsolutno najvećim udjelom u ukupnom izvozu. U ukupnoj vrijednosti prodaje industrijskih proizvoda u 2015. godini, prerađivačka industrija sudjeluje s 83,5 % (Državni zavod za statistiku, www.dzs.hr, 22. 6. 2017.). Industrija je u 2015. godini ostvarila izvoz od 10,9 milijardi eura, što je 94,5 % ukupnog izvoza. Izvozna orijentiranost najsnažnija je u tradicionalnim granama prerađivačke industrije: metaloprerađivačka industrija sudjeluje s 24,9 %, kemija, proizvodnja kemikalija i kemijskih proizvoda, proizvodnja plastike i gume te farmaceutska industrija s 13,7 %, proizvodnja računala, električnih proizvoda i električne opreme s 9,5 %, proizvodnja prehrambenih proizvoda s 8,1 %, proizvodnja naftnih derivata sa 6,8 % te drvna industrija s 4,9 % (Hrvatska gospodarska komora, www.hgk.hr, 13. 5. 2017.).


Kao takva, prerađivačka industrija trebala bi biti najvažniji oslonac gospodarstva Republike Hrvatske i njegova glavna strateška odrednica. Prerađivačku industriju u Hrvatskoj u proteklom su razdoblju karakterizirale promjene koje se očituju u povećanju važnosti i obujma proizvodnje onih djelatnosti za koje se smatra da nisu tehnološki, tj. za koje se pretpostavlja da nisu inovacijski intenzivne¹¹ (djelatnosti niske i niže srednje tehnološke razine). Takve promjene govore o tome da je potrebno poduzimati aktivnosti na promjeni strukture prerađivačke industrije u Republici Hrvatskoj u smjeru podizanja konkurentnosti i sposobnosti proizvodnje izvoznih proizvoda s višom dodanom vrijednošću, imajući u vidu činjenicu da je Hrvatska malo i otvoreno gospodarstvo u razvoju koje mora izvoziti da bi ostvarilo gospodarski rast i ekonomski prosperiralo (www.mingo.hr, 5. 10. 2016.).

Konkurentne i efikasne industrije visoke i niske tehnološke razine primarno ovise o sposobnosti samih industrija da se neprekidno prilagođavaju i reagiraju na promjene u okruženju te svoje aktivnosti usmjeravaju na strukturne reforme i prilagodbe zahtjevima tržišta. Zadatak je države neprestano unaprjeđivati uvjete za odvijanje tih aktivnosti. Također, intervencija države potrebna je samo u iznimnim slučajevima (npr. tržišnih neuspjeha) s ciljem doprinošenja efikasnijem funkcioniranju tržišta i stvaranju povoljnijeg poduzetničkog okvira.

¹¹ Mjereno udjelom prihoda uloženog u inovacijske aktivnosti*

Na grafikonu 1 prikazan je inovacijski pokazatelj EU-a pod nazivom kompozitni pokazatelj inovacijskog učinka ¹² (*Composite Innovation Indicator*) koji je usmjeren isključivo prema mjerenju inovacijskog sveukupnog rezultata.

Grafikon 1: Kompozitni pokazatelj inovacijskog učinka europskih zemalja



Napomena: Rezultati zemalja za 2011. (plavi stupci) i 2010. (crveni rombovi). Prosjek EU-a postavljen na 100 u 2010.

Izvor: Europska komisija. (2011). European Industrial Structure: Trends and Performances.

Na grafikonu 1 jasno su prikazani rezultati inovacijskog pokazatelja te on upućuje na položaj Republike Hrvatske u krugu europskih zemalja. Kompozitni pokazatelj inovacijskog učinka ukazuje na stagnaciju Hrvatske u promatranom razdoblju i priličan odmak od prosjeka EU-a. Pozicija Republike Hrvatske na granici je između umjerenih (*moderate*) i skromno inovativnih (*modest innovators*) zemalja u društvu Poljske, Bugarske, Latvije, Litve i Portugala.

¹² Predloženi pokazatelj temelji se na četirima komponentama:

1. tehnološkim inovacijama mjerenima prema patentima
2. zaposlenosti u znanjem intenzivnim aktivnostima kao postotku ukupne zaposlenosti
3. konkurentnosti znanjem intenzivnih roba i usluga. To se temelji na doprinosu trgovinske bilance *high-tech* i *medium-tech* proizvoda u ukupnoj trgovinskoj bilanci te znanjem intenzivnim uslugama kao udio izvoza ukupne usluge
4. zaposlenosti u brzorastućim tvrtkama inovativnih sektora.

U nadolazećem razdoblju nužno je definirati nove mjere koje će pokrenuti novi industrijski zamah, pri čemu bi najvažniji trendovi u idućem srednjoročnom razdoblju trebali biti: nastavak procesa strukturnih prilagodbi i reformi u ekonomskom sustavu, repozicioniranje tradicionalnih industrija i djelatnosti s pomakom prema proizvodima više dodane vrijednosti, povećavanje konkurentnosti prerađivačke industrije, povećana briga o zaštiti okoliša i održivom razvoju provedbom usvojenih direktiva, ulaganje u tehnologiju i inovacije, ubrzanje prilagodbi potrebama tržišta, fleksibilnost na tržištu radne snage. U središtu industrijske politike Hrvatske treba biti ekonomsko restrukturiranje kojemu je cilj dinamiziranje gospodarske aktivnosti i povećanje proizvodnosti u svim gospodarskim sektorima, od prerađivačke industrije do poljoprivrede i turizma.

Kako bi se smanjio jaz između potražnje i ponude proizvoda više i niže razine tehnološke složenosti, hrvatskoj prerađivačkoj industriji nužna je tehnološka obnova. Stoga mjere industrijske politike moraju biti usmjerne na povećanje konkurentnosti na međunarodnom tržištu kroz poboljšanje tehnološke razine domaćih poduzetnika, poticanjem istraživanja i razvoja, obrazovanjem zaposlenika kao i privlačenjem izravnih inozemnih ulaganja usmjerenih u sektore više i niže razine tehnološke intenzivnosti.

U tom smislu, Ministarstvo gospodarstva kroz Sektor za industrijsku politiku (www.mingo.hr, 7. 10. 2016.):

- utječe na povećanje konkurentnosti hrvatskoga gospodarstva kroz programe poticanja održivog industrijskog razvoja i restrukturiranja pojedinih grana industrije i pojedinih gospodarskih subjekata, prvenstveno poticanjem investicija u razvoj i istraživanje, primjenu novih tehnologija i inovacija u proizvodnom procesu te primjenu tehnologija za zaštitu okoliša i energetske učinkovitost, i to sustavom horizontalnih i regionalnih državnih potpora. U tom smislu, Sektor za industrijsku politiku osmišljavat će i provoditi operativne programe potpora za očuvanje i podizanje konkurentnosti u različitim sektorima prerađivačke industrije,
- razvija instrumente i mjere nove industrijske politike te sudjeluje u izradi strateških razvojnih dokumenata iz područja prerađivačke, drvoprerađivačke i prehrambene industrije,

- predlaže i provodi mjere za očuvanje zaposlenosti i poticanje izvoza u industrijskim sektorima.

U tom pogledu izrađena je „Industrijska strategija za razdoblje 2014. – 2020.”¹³ kojom se definiraju razvojne politike za prerađivačku industriju u ciljanom razdoblju, a Strategija je usklađena sa strateškim europskim dokumentom „Europa 2020.”. Industrijska strategija Republike Hrvatske 2014. – 2020. Izrađena je da bi se analizom industrije dobio pregled stanja industrijskih djelatnosti i poddjelatnosti kako bi se utvrdile perspektive rasta i razvoja te jačanja konkurentnosti, utvrdili strateški ciljevi, usvojio smjer djelovanja i alokacije resursa potrebnih za ostvarenje tih ciljeva, odnosno provedbeni model, te kako bi se pratila provedba Strategije. Ciljevi izrade dokumenta uključuju: definiranje i izradu metodološke osnove, analizu strateških smjernica Europske unije, analizu kvantitativnih i kvalitativnih obilježja hrvatske industrije, razvoj modela vrednovanja industrijskih poddjelatnosti, utvrđivanje strateških ciljeva i prioritetnih područja, utvrđivanje mjera realizacije strateških ciljeva, razvoj modela provedbe Strategije i izradu plana aktivnosti provedbe Strategije.

Također, radi povezivanja i potpore rastu inovacija i razvoju ključnih gospodarskih sektora u Republici Hrvatskoj, na 200. sjednici Vlade Republike Hrvatske održanoj 17. prosinca 2014. godine donesena je Strategija poticanja inovacija Republike Hrvatske 2014. – 2020. Akcijskim planom obuhvaćene su aktivnosti za dostizanje strateških ciljeva Strategije, a to su: poboljšati inovacijsku izvedbu RH, povećati udio ulaganja poslovnog sektora u ukupnim ulaganjima u istraživanje i razvoj, povećati broj temeljnih i primijenjenih istraživanja i povećati broj ljudskih kapaciteta za istraživanje, tehnološki razvoj i inovacije.

¹³ Izglasana na sjednici Hrvatskog sabora 17. listopada 2014.

Podjela po tehnološkoj intenzivnosti

Pojedine djelatnosti određuju se prema klasifikaciji tehnološke intenzivnosti OECD-a, točnije prema ISIC Rev. 2 (kasnije nadograđena ISIC Rev. 3).¹⁴ Europska komisija, tj. Eurostat preuzeo je i prilagodio definiciju ISIC klasifikacije u standardnu europsku klasifikaciju proizvodnih ekonomskih aktivnosti NACE Rev.1, a nešto kasnije u NACE Rev.2.

Slika 7: Klasifikaciju proizvodnih ekonomskih aktivnosti



↓ Referentna klasifikacija.

Izvor: Obrada autora prema Eurostatu (2008, str. 13.)

NACE Rev. 2 (na dvije i tri znamenke) svrstava djelatnosti u četiri skupine:

1. visoka tehnološka razina (*engl. High Technology*)
2. srednje visoka tehnološka razina (*engl. Medium High Technology*)
3. srednje niska tehnološka razina (*engl. Medium Low Technology*)
4. niska tehnološka razina (*engl. Low Technology*).

¹⁴ Klasifikacija se temelji na prijedlogu Hatzichronoglou (1997). Uvedene su četiri kategorije: *high*, *medium-high*, *medium-low* i *low* tehnologija, op.a.

Pojmovi visoka, srednje visoka, srednje niska i niska tehnološka razina upotrebljavaju se u skladu s OECD-ovom (1994) klasifikacijom.¹⁵ Ova definicija temelji se na relativnim izdancima tvrtki ili sektora za istraživanje i razvoj (R&D):

Istraživanje i razvoj: Prihod

| | |
|---|--------------------|
| <i>Visoka tehnološka razina</i> | <i>> 5 %</i> |
| <i>Srednje visoka tehnološka razina</i> | <i>3 % – 5 %</i> |
| <i>Srednje niska tehnološka razina</i> | <i>0,9 % – 3 %</i> |
| <i>Niska tehnološka razina</i> | <i>< 0,9 %</i> |

Pojam „niske tehnološke razine” ili „low-tech” označava one industrijske sektore koji u prosjeku imaju nizak ili nikakav udio izdataka istraživanja i razvoja u svojim prihodima, tj. njihov je R&D intenzitet ispod 0,9 %. Sektori s R&D intenzitetom višim od 5 % karakteriziraju se kao „visoka tehnološka razina” ili „high-tech”, a oni s R&D intenzitetom između 3 % i 5 % kao „srednje visoka tehnološka razina” ili „medium-high-tech”. Sektori R&D intenziteta između 3 % i 0,9 % klasificirani su kao „srednje niska tehnološka razina” ili „medium-low-tech”.

Prema NACE Rev 2., najveći broj djelatnosti u prerađivačkoj industriji pripada poduzećima niske tehnološke razine (11 od 24), dok je najmanji broj poduzeća klasificiran kao poduzeća visoke tehnološke razine (2 od 24).

Unutar poduzeća visoke tehnološke razine klasificirane su djelatnosti:

- **C21** Proizvodnja osnovnih farmaceutskih proizvoda i farmaceutskih pripravaka,
- **C26** Proizvodnja računala te elektroničkih i optičkih proizvoda, i
- **C30.3** Proizvodnja zrakoplova i svemirskih letjelica te srodnih prijevoznih sredstava i opreme

¹⁵ Klasifikacija tehnološke intenzivnosti jest relativna. Mnoge prerađivačke aktivnosti mogu se smatrati „visokotehnološkima”, ali, gledajući izravni intenzitet, R&D klasifikacija vrši se na temelju relativno novih R&D rezultata. Također, „visokotehnološke” industrije mogu obuhvatiti čitav niz proizvoda u rasponu između „niskotehnološke” i „visokotehnološke” razine. Ideja je bila stvoriti klasifikaciju za OECD kao cjelinu. Pojedine zemlje mogu imati malo drugačije klasifikacije iako primjenjuju jednake metode i kompromise na razini industrije, primjerice zbog opće dostupnosti podataka.

Prema MINGO-u (2014), navedene djelatnosti ostvarile su u 2012. godini 7,83 % ukupne bruto dodane vrijednosti prerađivačke industrije i zapošljavale 10 006 osoba, odnosno 4,46 % ukupnog broja zaposlenih u prerađivačkoj industriji.

Pod prerađivačka poduzeća srednje visoke tehnološke razine klasificirane su djelatnosti:

- **C20** Proizvodnja kemikalija i kemijskih proizvoda,
- **C25.4** Proizvodnja oružja i streljiva
- **C27** Proizvodnja električne opreme,
- **C28** Proizvodnja strojeva i uređaja, d. n.,
- **C29** Proizvodnja motornih vozila, prikolica i poluprikolica,
- **C30** Proizvodnja ostalih prijevoznih sredstava **izuzev C30.1** Gradnja brodova i čamaca i **izuzev C30.3** Proizvodnja zrakoplova i svemirskih letjelica te srodnih prijevoznih sredstava i opreme, i
- **C32.5** Proizvodnja medicinskih i stomatoloških instrumenata i pribora.

Prethodno navedene djelatnosti u 2012. ostvarile su 24,14 % ukupne bruto dodane vrijednosti prerađivačke industrije i zapošljavale ukupno 41 595 osoba, odnosno 18,53 % ukupnog broja zaposlenih u prerađivačkoj industriji. Najveću bruto dodanu vrijednost u ovoj skupini djelatnosti ostvarila je djelatnost C30 Proizvodnja ostalih prijevoznih sredstava, a ujedno, i apsolutno i relativno gledano, zapošljava najveći broj zaposlenih. Jednako tako, djelatnost C30 iskazuje najveću produktivnost s obzirom na to da je omjer ostvarene bruto dodane vrijednosti i broja zaposlenih najveći.¹⁶

Pod prerađivačka poduzeća srednje niske tehnološke razine klasificirane su djelatnosti:

- **C19** Proizvodnja koksa i rafiniranih naftnih proizvoda,
- **C22** Proizvodnja proizvoda od gume i plastike,
- **C23** Proizvodnja ostalih nemetalnih mineralnih proizvoda,
- **C24** Proizvodnja metala,

¹⁶ Podatci dobiveni iz financijskih izvještaja (Industrijska strategija Republike Hrvatske 2014. – 2020.)

- **C25** Proizvodnja gotovih metalnih proizvoda, osim strojeva i opreme **izuzev C25.4** Proizvodnja oružja i streljiva,
- **C30.1** Gradnja brodova i čamaca, i
- **C33** Popravak i instaliranje strojeva i opreme.

Navedene djelatnosti u 2012. ostvarile su 36,08 % ukupne bruto dodane vrijednosti prerađivačke industrije i zapošljavale ukupno 62 758 osoba, odnosno 27,88 % ukupnog broja zaposlenih u prerađivačkoj industriji. Djelatnost C19 Proizvodnja koksa i rafiniranih naftnih proizvoda ostvaruje najveći omjer bruto dodane vrijednosti i broja zaposlenih, iskazujući time najveću produktivnost u ovoj skupini djelatnosti. S druge strane, relativno nisku bruto dodanu vrijednost u odnosu na broj zaposlenih ostvaruje djelatnost C25 Proizvodnja gotovih metalnih proizvoda, osim strojeva i opreme (MINGO, 2014).

Pod prerađivačka poduzeća niske tehnološke razine klasificirane su djelatnosti:

- **C10** Proizvodnja prehrambenih proizvoda,
- **C11** Proizvodnja pića,
- **C12** Proizvodnja duhanskih proizvoda,
- **C13** Proizvodnja tekstila,
- **C14** Proizvodnja odjeće,
- **C15** Proizvodnja kože i srodnih proizvoda,
- **C16** Prerada drva i proizvoda od drva i pluta, osim namještaja; proizvodnja proizvoda od slame i pletarskih materijala,
- **C17** Proizvodnja papira i proizvoda od papira,
- **C18** Tiskanje i umnožavanje snimljenih zapisa,
- **C31** Proizvodnja namještaja, i
- **C32** Ostala prerađivačka industrija **izuzev C32.5** Proizvodnja medicinskih i stomatoloških instrumenata i pribora.

Navedene nisko tehnološki intenzivne djelatnosti u 2012. ostvarile su 31,95 % ukupne bruto dodane vrijednosti prerađivačke industrije i zapošljavale 110 262 osobe, odnosno 49,13 %

ukupnog broja zaposlenih u prerađivačkoj industriji. Najveću bruto dodanu vrijednost u ovoj skupini djelatnosti u 2012. ostvarila je djelatnost C10 Proizvodnja prehrambenih proizvoda u kojoj je ujedno bio i najveći broj zaposlenih. S druge strane, ovdje je bitno naglasiti da je omjer udjela bruto dodane vrijednosti i broja zaposlenih u ovoj djelatnosti na niskoj razini, dok se kao produktivne prema tom kriteriju u ovoj skupini djelatnosti ističu C11 Proizvodnja pića i C12 Proizvodnja duhanskih proizvoda (MINGO, 2014).

Na razini cijele prerađivačke industrije, najveći udio bruto dodane vrijednosti u ukupnoj bruto dodanoj vrijednosti prerađivačke industrije u 2012. ostvarila je skupina djelatnosti klasificirana kao srednje nisko tehnološki intenzivna. S druge strane, najveći je udio zaposlenih u nisko tehnološki intenzivnim djelatnostima, a ova je skupina djelatnosti i najmanje produktivna.

4.3. Faza 1 – Analiza i ocjena hrvatskih poduzeća s niskom i srednje niskom tehnološkom razinom (HR NTP) (H1 do H4)

Za prvu fazu istraživanja te testiranje prvih četiriju hipoteza upotrijebljeni su cenzus-podatci koje je prikupio Državni zavod za statistiku (DZS) obrascem Inovacijske aktivnosti poduzeća (INOV) za razdoblje 2010. – 2012. Upitnik je u skladu s Eurostatovim istraživanjem Community Innovation Survey (CIS).¹⁷ Također, upitnik su dužna ispuniti sva poduzeća¹⁸, neovisno o tome jesu li u razdoblju 2010. – 2012. provodila inovacijske aktivnosti. Ključna prednost istraživanja Community Innovation Survey, tj. INOV upitnika kao empirijske baze jest u tome što mjeri izlazne inovacijske pokazatelje za inovacije proizvoda. Udio prihoda

¹⁷ Community Innovation Survey – CIS (npr. sedmo CIS istraživanje – 2010.) istražuje inovativne aktivnosti u poduzećima. Harmonizirani upitnik dizajniran je za pružanje informacija o inovativnosti sektora prema vrsti poduzeća, o različitim vrstama inovacija te o različitim aspektima razvoja inovacije, kao što su ciljevi, izvori informacija, javnog financiranja, izdaci za inovacije itd. CIS pruža statistiku razrađenu prema zemljama, tipu inovacija, gospodarskih aktivnosti i razredima. CIS podaci dostupni s promjenjivim detaljima u četrdesetak zemalja, redovno se svake četiri godine prikupljaju na razini poduzeća (sa smanjenim ispitivanjima svake dvije godine). Zemlje članice EU-a, zemlje kandidatkinje, Norveška i Island) primjenjuju usklađenu metodu upitnika i ispitivanja. Podatke prikupljaju nacionalni statistički uredi ili istraživački instituti. Rezultati ispitivanja obrađuju se na nacionalnoj razini putem zajedničke metodologije, a poslije u Eurostatu kako bi se omogućila usporedba među zemljama.


¹⁸ Izvještajne jedinice jesu sva poduzeća, tj. pravne i fizičke osobe s deset ili više zaposlenih koje su u Statističkome poslovnom registru (SPR) razvrstane u područja B, C, D, E, F, H, J, K, L i odjeljke 46, 71, 72, 73 prema Nacionalnoj klasifikaciji djelatnosti – NKD 2007

generiranog od novih ili značajno poboljšanih proizvoda u ukupnim prihodima u zadnje tri godine pokazatelj koji istraživači često upotrebljavaju za analizu determinanti inovacijskog uspjeha (pogledati Laursen, Salter, 2006; Rammer *et al.*, 2009; Leiponen, Helfat, 2010; Cockburn *et al.*, 2010). Drugi pokazatelj inovacijskog uspjeha jest udio prihoda od inovacija proizvoda novih za tržište u ukupnim prihodima. Proizvodi novi za tržište oni su proizvodi koje nijedno drugo poduzeće nije prije uvelo na tržište. Relevantno tržište definira inovativno poduzeće i ono se ne mora odnositi na globalno tržište, već većinom na nacionalno ili regionalno tržište. U ovom istraživanju na temelju relevantne metodologije (Likar *et al.*, 2011) za mjerenje inovacijskih rezultata izabrana su dva pokazatelja:

RII: udio prihoda od inovacija proizvoda u ukupnim prihodima (%)

RMI: udio prihoda od inovacija proizvoda novih za tržište u ukupnim prihodima od inovacija (%)

Slika 8: Podjela na inovacijske skupine



Izvor: Obrada autora prema Likar *et al.* (2011)

Za podjelu poduzeća u inovacijske skupine (slika 8), tj. za granicu podjele, određene su medijanske vrijednosti¹⁹ pokazatelja (RII = 20, RMI = 25). Na taj su način definirane tri skupine poduzeća:

- 0 – neinovativna poduzeća (RII = 0, RMI = 0),
- 1 – inovacijski sljedbenici (RII ≤ 20, RMI ≤ 25) i
- 2 – inovacijsko vodeća poduzeća (RII > 20, RMI > 25)

Ukupni uzorak za potrebe istraživanja obuhvaća 996 srednje velikih i velikih²⁰ prerađivačkih poduzeća niske i srednje niske tehnološke razine (HR NTP), od čega 72 poduzeća pripadaju inovacijsko vodećim, 158 inovacijskim sljedbenicima i 766 neinovativnim poduzećima.

Tablica 9: Uzorak HR NTP

| | ukupni uzorak | neinovativna poduzeća (skupina 0) | inovacijski sljedbenici (skupina 1) | inovacijsko vodeći (skupina 2) |
|--|------------------|---|---|--------------------------------------|
| Hrvatska poduzeća niske i srednje niske tehnološke razine (HR NTP) | 996 | 766 | 158 | 72 |

Izvor: Autor

Grafikon 2 prikazuje strukturu hrvatskih poduzeća niske i srednje niske tehnološke razine (HR NTP) u razdoblju od 2010. do 2012. godine.

¹⁹ Medijan slučajnog uzorka jest vrijednost koja ima svojstvo da je 50 % podataka veće, a 50 % manje od vrijednosti


²⁰ Poduzetnici se razvrstavaju prema odredbama Zakona o računovodstvu (NN 78/2015), ovisno o pokazateljima utvrđenima zadnjega dana poslovne godine koja prethodi poslovnoj godini za koju se sastavljaju financijski izvještaji, a prema sljedećim uvjetima: iznos ukupne aktive, iznos prihoda i prosječan broj radnika tijekom poslovne godine.

1. Mali su poduzetnici oni koji ne prelaze dva od sljedećih uvjeta: ukupna aktiva 30.000.000,00 kuna, prihod 60.000.000,00 kuna ili prosječan broj radnika tijekom poslovne godine 50;

2. Srednji su poduzetnici oni koji prelaze dva od prethodno nabrojanih uvjeta, ali ne prelaze dva od sljedećih uvjeta: ukupna aktiva 150.000.000,00 kuna, prihod 300.000.000,00 kuna ili prosječan broj radnika tijekom poslovne godine 250;

3. Veliki su poduzetnici oni koji prelaze dva uvjeta iz točke 2.

Grafikon 2: Struktura HR NTP u pogledu inovacijske aktivnosti



Napomena: Neinovativni ($RII = 0$, $RMI = 0$), inovacijski sljedbenici ($RII \leq 20$, $RMI \leq 25$) i inovacijsko vodeći ($RII > 20$, $RMI > 25$).

Izvor: Obrada autora

Vidljivo je da u razdoblju od 2010. do 2012. godine u ukupnom uzorku svih srednje velikih i velikih hrvatskih prerađivačkih poduzeća niske i srednje niske tehnološke razine (HR NTP) s udjelom od 77 % prevladavaju neinovativna poduzeća (skupina 0). Udio inovacijskih sljedbenika jest 16 %, dok je udio inovacijsko vodećih poduzeća ($RII > 20$, $RMI > 25$) samo 7 % ili više od deset puta manje od neinovativnih

Radi provjere, odnosno postupka donošenja odluke o prihvaćanju ili odbacivanju prvih triju hipoteza (*H1-H3*), visini i strukturi inovacijskih ulaganja te efikasnosti inovacijskog procesa inovacijsko vodećih, inovacijskih sljedbenika i neinovativnih hrvatskih NTP, provedeni su statistički testovi. Statistička analiza provedena je računalnim programom *IBM SPSS Statistics 23*. Za testiranje statistički značajne razlike u visini inovacijskih ulaganja inovacijskih skupina postavljena je sljedeća hipoteza:

H1: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP

Za testiranje prve hipoteze (i, u nastavku, druge) iz podataka koje prikuplja Državni zavod za statistiku obrascem Inovacijske aktivnosti poduzeća (INOV) za razdoblje 2010. – 2012. godine izdvojene su sljedeće varijable koje opisuju visinu i strukturu ulaganja HR NTP u inovacijske aktivnosti:

RRDINX – troškovi poduzeća iskazani u tisućama kuna za vlastite aktivnosti istraživanja i razvoja

RRDEXX – troškovi poduzeća iskazani u tisućama kuna za vanjske usluge istraživanja i razvoja


RMACX – troškovi poduzeća iskazani u tisućama kuna za nabavu postrojenja, opreme, softvera i zgrada

ROEKX – troškovi poduzeća iskazani u tisućama kuna za nabavu postojećeg znanja od drugih poduzeća ili organizacija

ROTRX – troškovi poduzeća iskazani u tisućama kuna za sve ostale inovacijske aktivnosti uključujući dizajn, osposobljavanje, marketing i druge relevantne aktivnosti.

Na grafikonu 3 prikazani su visina i struktura ulaganja triju inovacijskih skupina srednje velikih i velikih prerađivačkih poduzeća niske i srednje niske tehnološke razine (HR NTP), inovacijsko vodeća poduzeća, inovacijski sljedbenici i neinovativna poduzeća. Visina i struktura prikazane su kao udio inovacijskih ulaganja u ukupnim prihodima poduzeća.

Grafikon 3: Visina i struktura ulaganja HR NTP u inovacijske aktivnosti



Napomena: Neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2.

Na ordinati (y-osi) prikazan je udio u ukupnim prihodima poduzeća.

Izvor: Obrada autora

Iz grafikona je jasno vidljivo da inovacijsko vodeća poduzeća po visini i strukturi najviše ulažu u inovacijske aktivnosti, i to 0,57 % svojih prihoda. Inovacijski sljedbenici ulažu 0,28 %, a neinovativna poduzeća 0,13 % svojih prihoda. Prosječno gledano, HR NTP uložila su u 2012. godini skromnih 0,33 % svojih prihoda u inovacijske aktivnosti. Postoji vjerojatnost da su kratkoročne komponente u aktivnostima istraživanja i razvoja povezane s cikličkim obrazcem u gospodarskoj aktivnosti. Drugim riječima, u ovom je slučaju nizak udio inovacijskih ulaganja možebitno povezan s razdobljem recesije u kojem se nalazila Hrvatska. Primjerice, nakon svjetske recesije početkom 1990-ih, u većini zemalja OECD-a dogodio se pad izdataka za istraživanje i razvoj (Heger, 2004).

Promatranjem strukture ulaganja vidi se da se većinom ulaže u nabavu postrojenja, opreme, softvera i zgrada (*RMACX*; 0,21 % prihoda u ukupnom uzorku) te se može pretpostaviti da se takvim investicijama značajnije potiču procesne inovacije u odnosu na inovacije proizvoda. Kod neinovativnih poduzeća ulaganja su gotovo u cijelosti u prethodno spomenutu kategoriju (93,44 %). Struktura ulaganja inovativno vodećih poduzeća jest sljedeća: 54,98 % inovacijskih ulaganja ide u nabavu postrojenja, opreme, softvera i zgrada, 30,78 % u vlastite aktivnosti istraživanja i razvoja (*RRDINX*), 7,09 % za sve ostale inovacijske aktivnosti, uključujući dizajn, osposobljavanje, marketing i druge relevantne aktivnosti (*ROTRX*), 4,86 % u vanjske usluge istraživanja i razvoja (*RRDEXX*) i 2,29 % za nabavu postojećeg znanja od drugih poduzeća ili organizacija (*ROEKX*). Inovacijski sljedbenici 68,15 % ulažu u nabavu postrojenja, opreme, softvera i zgrada, 15,06 % u vlastite aktivnosti istraživanja i razvoja, 12,53 % u sve ostale inovacijske aktivnosti, uključujući dizajn, osposobljavanje, marketing i druge relevantne aktivnosti, 2,70 % za nabavu postojećeg znanja od drugih poduzeća ili organizacija i 1,56 % u vanjske usluge istraživanja i razvoja.

S obzirom na prosječnu vrijednost pokazatelja iz grafikona 3, razumno je za pretpostaviti da među trima skupinama poduzeća postoji značajna razlika u visini njihovih inovacijskih ulaganja. Za provjeru pretpostavke u nastavku će se primijeniti parametrijski ili neparametarski statistički testovi, uzimajući pritom u obzir distribuciju podataka.

Za statističko testiranje visine inovacijskih ulaganja skupine inovacijsko vodećih poduzeća i skupine neinovativnih poduzeća upotrijebljen je Mann-Whitneyjev neparametrijski test (tablica 10). S obzirom na to da se distribucija podataka razlikuje od normalne distribucije (utvrđeno pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom), predloženi test prikladan je za testiranje hipoteze *H1*.

Tablica 10: Mann-Whitneyjev test o visini inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP

| | <i>ukupna inovacijska ulaganja/prihod</i> |
|-----------------------------|---|
| Mann-Whitney U ^a | 7537,000 |
| Wilcoxon W | 301298,000 |
| Z | -15,229 |
| Asymp. Sig. (2-tailed) | 0,000*** |

^a Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI)

*** Signifikantnost na razini pouzdanosti od 99 %

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva U-testa potvrđuju ono što je iz grafikona 3 jasno vidljivo, a to je postojanje razlike u rangovima ukupnih inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP. Na razini značajnosti $\alpha = 0,05$ (5 %) navedeni je test statistički značajan (signifikantnost testa iznosi 0,000). Ovim testom nije dana potpora²¹ (odbacuje se) prvoj hipotezi (*H1*) te se može zaključiti da postoji statistički značajna razlika u visini inovacijskih ulaganja između skupine inovacijsko vodećih poduzeća i neinovativnih HR NTP. Inovacijsko vodeća poduzeća više i raznovrsnije ulažu svoja sredstva u odnosu na skupinu neinovativnih hrvatskih poduzeća niske i srednje niske tehnološke razine.

H2: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP

²¹ Odbacivanjem hipoteze *H1* prihvaća se hipoteza *H1_A*, a prihvaćanjem *H1* odbacuje se *H1_A*. *H1* zove se nul-hipoteza, a *H1_A* alternativna hipoteza.

Za utvrđivanje statistički značajne razlike u visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP također je upotrijebljen Mann-Whitneyjev neparametrijski test (tablica 11).

Tablica 11: Mann-Whitneyjev test o visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP

| | <i>ukupna inovacijska ulaganja/prihod</i> |
|-----------------------------|---|
| Mann-Whitney U ^a | 4698,000 |
| Wilcoxon W | 17259,000 |
| Z | -2,123 |
| Asymp. Sig. (2-tailed) | 0,034** |

^a Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI)

** Signifikantnost na razini pouzdanosti od 95 %


Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva testa potvrđuju postojanje razlike u rangovima ukupnih inovacijskih ulaganja HR NTP. Navedeni je test statistički značajan (signifikantnost testa iznosi 0,034). Ovim testom nije dana potpora (odbacuje se) drugoj hipotezi (*H2*) te se može zaključiti da postoji statistički značajna razlika u visini inovacijskih ulaganja skupine inovacijsko vodećih poduzeća i inovacijskih sljedbenika HR NTP. Inovacijsko vodeća poduzeća više i raznovrsnije ulažu svoja sredstva u inovacijske aktivnosti u odnosu na skupinu inovacijski sljedbenici.

H3: Ne postoji statistički značajna razlika u efikasnosti inovacijskog procesa inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna HR NTP

Produktivnost inovacijskog procesa HR NTP prikazuje koliko je učinaka ostvareno s utrošenim sredstvima. Produktivnost, tj. učinkovitost povrata sredstava uloženi u inovacijske aktivnosti, mjeri se kao omjer ukupnih prihoda od inovacija i ukupnih ulaganja u inovacije. Na grafikonu 4 prikazana je produktivnost inovacijskog procesa svih triju promatranih skupina HR NTP.

Grafikon 4: Produktivnost inovacijskog procesa HR NTP



Napomena: Neinovativni (RII = 0, RMI = 0), inovacijski sljedbenici (RII \leq 20, RMI \leq 25) i inovacijsko vodeći (RII $>$ 20, RMI $>$ 25).

Na ordinati (y-osi) prikazan je povrat na inovacijska ulaganja.

Izvor: Obrada autora

Inovacijsko vodeća poduzeća za jednu kunu uloženu u inovacijske aktivnosti ostvaruju povrat, tj. prihod od inovacija, od 56,62 kn te imaju za 37,11 kn veći povrat od skupine inovacijskih sljedbenika (19,51 kn). Uzimajući u obzir da na prihod od inovacija, osim visine i strukture ulaganja u inovacije, utječu i procesni inovacijski čimbenici poput organizacije i upravljanja inovacijskim procesom, ovakvi rezultati ne iznenađuju. Također je poznato da su inovacijsko vodeća poduzeća i inovacijski sljedbenici u svoje inovacijske aktivnosti uložili prilično skromnih 0,57 %, odnosno 0,28 % svojih prihoda, što prilično „iskrivljuje” realnu sliku inovacijske produktivnosti.

Za statističko testiranje produktivnosti inovacijskog procesa korišten je Mann-Whitneyjev neparametrijski test. S obzirom na to da se distribucija podataka značajno razlikuje se od normalne distribucije (utvrđeno pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom), ovaj je test prikladan za testiranje hipoteze o efikasnosti inovacijskog procesa inovacijsko vodećih hrvatskih NTP u odnosu na inovacijske sljedbenike i neinovativna NTP.

Tablica 12: Mann-Whitneyjev test o produktivnost inovacijskog procesa HR NTP

| | <i>Produktivnost inovacijskog procesa</i> | |
|------------------------|---|-----------|
| | (0 vs 2) ^a | (1 vs 2) |
| Mann-Whitney U | 4596,000 | 4528,000 |
| Wilcoxon W | 298357,000 | 17089,000 |
| Z | -26,182 | -2,488 |
| Asymp. Sig. (2-tailed) | 0,000*** | 0,013** |

^a Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

*** Signifikantnost na razini pouzdanosti od 99 %; ** Signifikantnost na razini pouzdanosti od 95 %

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva testa potvrđuju postojanje razlike u produktivnosti inovacijskog procesa NTP. Navedeni je test statistički značajan. Signifikantnost testa kod skupina neinovativnih i inovacijsko vodećih poduzeća (0 vs 2) iznosi $p = 0,000$, a kod skupina inovacijskih sljedbenika i inovacijsko vodećih HR NTP (1 vs 2) $p = 0,013$. Shodno tome, ovim testom nije dana potpora (odbacuje se) trećoj hipotezi (H_3) te se može zaključiti da postoji statistički značajna razlika u produktivnosti inovacijskog procesa skupine inovacijsko vodećih poduzeća i skupina inovacijskih sljedbenika i neinovativnih HR NTP.

H4: Ne postoji statistička razlika u financijski izraženoj efikasnosti inovacijsko vodećih HR NTP u odnosu na inovacijske sljedbenike i neinovativna HR NTP

U ovom se istraživanju financijska efikasnost analizira kroz pokazatelje rasta: prihod i dodanu vrijednost, pokazatelje profitabilnosti ili rentabilnosti: stopu dobiti ili maržu profita (ROS), povrat na angažiranu imovinu (ROA), povrat na uloženi kapital (ROE) i pokazatelj ekonomičnosti kao odnos ostvarenih ukupnih prihoda i ukupnih rashoda. Za mjerenje razlika u financijskoj efikasnosti među skupinama HR NTP i testiranje hipoteze potrebni su sekundarni podatci hrvatske Financijske agencije (FINA).

U svrhu javnog objavljivanja, sva hrvatska poduzeća dužna su Financijskoj agenciji dostaviti godišnja financijska izvješća i izvješća revizora radi statističke i druge potrebe do 30. travnja sljedeće godine. Obveznici predaje financijskih izvještaja jesu poduzetnici iz realnog i financijskog sektora, neprofitne organizacije i proračunski korisnici. Registar godišnjih financijskih izvještaja središnji je izvor informacija o uspješnosti poslovanja i financijskom položaju pravnih i fizičkih osoba koje su obveznici poreza na dobit. Statistika poduzeća obuhvaća i pokriva sve veličine poduzeća, od najmanjih poduzeća bez zaposlenika do najvećih poduzeća s desecima tisuća zaposlenika, sve pravne oblike i sve industrije koje su klasificirane prema djelatnostima sukladno NKD-u 2007., što je izravno usporedivo s klasifikacijom NACE Rev. 2.

Utjecaj inovativnosti na prihode poduzeća izravan je jer se poboljšanjima i inovacijama u proizvode, usluge, marketinške aktivnosti i druge vrste inovacija utječe na cijenu i potražnju. Dodana vrijednost jest kategorija koja proizlazi iz svih aktivnosti poduzeća u realizaciji učinaka umanjenih za troškove i ostale inpute, u ovom slučaju inovacija i stoga se smatra važnim pokazateljem rasta i konkurentske prednosti. Dodana vrijednost pokriva bruto plaće radnika te ostale isplate i nadoknade koje su isplaćene radnicima, plaćeni porez na dobit, amortizaciju i dobit. Inovativnost je pokretač rasta, kvaliteta je pokretač dobiti, a oboje su pokretači tržišne vrijednosti (Cho, Pucik, 2005, 569). Rezultati istraživanja koje su proveli Sethibe i Steyn (2016) potvrđuje da su profitabilnost, rast prihoda i povrat na angažiranu imovinu (ROA) najčešće korišteni financijski pokazatelji rezultata poslovanja u relaciji s inovativnosti.

Da bismo dobili uvid u moguću razliku u financijski izraženoj efikasnosti među skupinama HR NTP, financijski su pokazatelji agregirani po skupinama poduzeća. Tablica 13 prikazuje prosječnu dodanu vrijednost po zaposlenom, prihod od prodaje i prihod od prodaje po zaposlenom svih triju promatranih inovacijskih skupina. Iznosi u tablici izraženi su u tekućim cijenama. Prosječna stopa inflacije za razdoblje od 1. 1. 2010. do 1. 1. 2013. iznosila je 2,2 % [DZS, www.dzs.hr, 18. 3. 2017.].

Tablica 13: Dodana vrijednost i prihod po skupinama HR NTP

| Pokazatelji | Ino. skupina | 2010 | 2011 | 2011/10 (%) | 2012 | 2012/11 (%) | 2012/10 (%) |
|--|--------------|--------------------|--------------------|--------------|--------------------|--------------|-------------|
| <i>Dodana vrijednost po zaposlenom</i> | V | 115.095 | 112.238 | -2,48 | 116.024 | 3,37 | 0,81 |
| | S | 144.428 | 143.030 | -0,97 | 139.343 | -2,58 | -3,52 |
| | N | 111.320 | 99.001 | -11,07 | 77.552 | -21,67 | -30,33 |
| <i>Prihod od prodaje</i> | V | 86.519.744 | 89.315.572 | 3,23 | 93.839.119 | 5,06 | 8,46 |
| | S | 180.812.451 | 197.691.578 | 9,34 | 196.540.098 | -0,58 | 8,70 |
| | N | 33.118.669 | 35.691.827 | 7,77 | 35.443.347 | -0,70 | 7,02 |
| <i>Prihod od prodaje po zaposlenom</i> | V | 442.671 | 511.779 | 15,61 | 457.236 | -10,66 | 3,29 |
| | S | 607.279 | 644.578 | 6,14 | 643.183 | -0,22 | 5,91 |
| | N | 461.321 | 442.246 | -4,13 | 437.682 | -1,03 | -5,12 |

Napomena: V = inovacijsko vodeći, S = inovacijski sljedbenici, N = neinovativni;

Iznosi u tekućim cijenama

Izvor: Obrada autora prema podacima FINA-e (2015)

Iz tablice 13 vidljivo je da skupina inovacijskih sljedbenika bilježi nešto više prosječne pokazatelje. Dodana vrijednost po zaposlenome jest, agregirano gledano, najviša u skupini inovacijskih sljedbenika, no rast pokazatelja prisutan je isključivo kod skupine inovacijski vodećih HR NTP (0,81 % na kraju 2012.). Kod prosječnog prihoda od prodaje i prihoda od prodaje po zaposlenom primjetna je slična pozicija HR NTP. Međutim, slijedeći Fatura i Likara (2010), između udjela prihoda od inovacija proizvoda u ukupnim prihodima i udjela prihoda od inovacija proizvoda novih za tržište u ukupnim prihodima od inovacija nema korelacije, stoga tvrtke s kvalitetnim inovacijama ne moraju nužno ostvariti značajnije prihode od njihove prodaje (i obrnuto).

Na sljedećoj tablici (14) prikazani su pokazatelji profitabilnosti inovacijskih skupina, povrat na prodaju, tj. profitna marža (ROS), povrat na imovinu (ROI), povrat na kapital (ROE) i povrat na investirano (ROI) te pokazatelj ekonomičnosti ukupnog poslovanja.

Tablica 14: Profitabilnost i ekonomičnost inovacijskih skupina HR NTP

| pokazatelji | ino skupina | 2010 | 2011 | 2011/10 (%) | 2012 | 2012/11 (%) | 2012/10 (%) |
|--|-------------|---------------|---------------|--------------|---------------|--------------|--------------|
| <i>ROS</i> | V | 2,061 | -0,966 | - | 2,012 | - | -2,38 |
| | S | 0,839 | 0,408 | -51,37 | -0,494 | -221,08 | -158,88 |
| | N | -9,900 | -10,414 | - | -2,978 | - | - |
| <i>ROA</i> | V | 3,199 | 3,269 | 2,19 | 5,730 | 75,28 | 79,12 |
| | S | 2,670 | 3,181 | 19,14 | 1,778 | -44,11 | -33,41 |
| | N | 3,678 | 2,959 | -19,55 | -2,447 | - | - |
| <i>ROE</i> | V | 17,506 | 25,368 | 44,91 | 11,551 | -54,47 | -34,02 |
| | S | 9,681 | 1,843 | -80,96 | -30,719 | - | - |
| | N | 13,279 | 13,056 | -1,68 | 14,963 | 14,61 | 12,68 |
| <i>ROI</i> | V | 6,728 | 8,547 | 27,04 | 8,220 | -3,83 | 22,18 |
| | S | 1,138 | 4,216 | 270,47 | 1,540 | -63,47 | 35,33 |
| | N | -0,703 | 14,754 | - | 7,330 | -50,32 | - |
| <i>Ekonomičnost ukupnog poslovanja</i> | V | 103,8 | 103,2 | -0,58 | 105,2 | 1,94 | 1,35 |
| | S | 103,1 | 103,1 | 0,00 | 102,5 | -0,58 | -0,58 |
| | N | 102,7 | 102,7 | 0,00 | 102,3 | -0,39 | -0,39 |

Napomena: V = inovacijsko vodeći, S = inovacijski sljedbenici, N = neinovativni; Pokazatelji u tekućim cijenama

Izvor: Obrada autora prema podacima FINA-e (2015)

U razdoblju od 2010. do 2012. godine kod inovacijsko vodećih poduzeća profitna marža (ROS) pala je za 2,38 %. U 2011. godini u odnosu na 2010. uslijedio je veliki pad te je profitna marža dosegla negativnu vrijednost. Međutim, u 2012. godini profitna marža iznosila je 2,01 % te je značajno viša nego kod skupina inovacijsko vodećih i neinovativnih HR NTP koji bilježe negativne pokazatelje. Što se tiče povrata na imovinu (ROA), skupina inovacijsko vodećih poduzeća prikazuje najviše prosječne vrijednosti pokazatelja u svim promatranim godinama. Također, jedino je kod inovacijsko vodećih poduzeća primjetan rast u svim godinama koji u konačnici iznosi 79,12 %. Kod ostala dva pokazatelja profitabilnosti, povrata na kapital (ROE) i povrata na investirano (ROI), također je vidljiva značajna razlika u pokazateljima između skupine inovacijsko vodećih i skupina inovacijskih sljedbenika i neinovativnih HR NTP, s iznimkom pokazatelja ROE u 2012. godini gdje skupina neinovativnih bilježi najvišu vrijednost. Generalno govoreći, primjetna je volatilnost svih pokazatelja profitabilnosti u promatranom razdoblju, vrlo vjerojatno uzrokovana recesijskim razdobljem. Nasuprot tome, gledajući po godinama, pokazatelj ekonomičnosti ukupnog poslovanja prilično je konstantan uz činjenicu da je u prosjeku značajno viši kod skupine inovacijsko vodećih HR NTP (105,2 u 2012.).


U ovoj fazi istraživanja testiranja hipoteze izvršit će se na temelju agregiranih financijskih podataka po skupinama HR NTP. S obzirom na iznose i pokazatelje iz tablica 13 i 14, vidljivo je da postoji statistička razlika u financijskim pokazateljima inovacijskih skupina te se u skadu s time može odbaciti hipoteza *H4* i zaključiti da postoji statistička razlika u financijski izraženoj efikasnosti inovacijsko vodećih HR NTP u odnosu na inovacijske sljedbenike i neinovativna HR NTP.

4.4. Faza 2 – Analiza i ocjena njemačkih poduzeća s niskom i srednje niskom tehnološkom razinom (DE NTP) (H5 do H7)

U njemačkom gospodarskom sustavu inovativnost je prepoznata kao glavni pokretač produktivnosti i rasta prihoda, dok su poduzetništvo i inovacije neraskidivo povezani. Suočena s globalnom financijskom krizom, njemačka se ekonomija pokazala iznimno elastičnom, a svojom izvedbom nadmašuje druga velika europska gospodarstva. Također, Njemačka se može pohvaliti snažnim inovacijskim ekosustavom te dinamičnim sektorom malih i srednjih poduzeća. Primjerice, u 2012. godini Njemačka je vodeći igrač u globalnim inovacijama i troši više od 2,9 % svojeg BDP-a na istraživanje i razvoj te tako s 9 % sudjeluje u OECD-ovim ukupnim troškovima istraživanja i razvoja. [OECD, www.oecd.org, 15. 6. 2015.].

Grafikon 5 prikazuje kompozitni pokazatelj²² koji mjeri inovacijske učinke, tj. do koje su mjere ideje iz inovativnih sektora u mogućnosti doći na tržište, pružiti bolja radnih mjesta te u konačnici učiniti Europu konkurentnijom.

Grafikon 5: Pozicija Njemačke prema kompozitnom pokazatelju inovacijskog učinka



Napomena: Rezultati zemalja za 2011. (crveni stupci) i 2010. (križići). Prosjek EU-a postavljen na 100 u 2010.

Izvor: Europska komisija (2012)

²² Kompozitni pokazatelj inovacijskog učinka (Summary innovation indeks) objedinjava 25 inovacijskih pokazatelja upotrijebljenih u izvješćima EU-a – Innovation Union Scoreboard

Iz grafikona je vidljiva snažna inovacijska pozicija Njemačke u 2011. godini. Njemačka zauzima visoko treće mjesto, odmah iza Japana i Švedske, a ispred Irske, Švicarske, Danske, Velike Britanije i SAD-a.

U pogledu prerađivačkih poduzeća niske tehnološke razine, statistički podatci Eurostata i istraživanja German Manufacturing Survey otkrivaju da su 2010. godini upravo ta poduzeća pridonijela s 51 % dodane vrijednosti u proizvodnji. Za usporedbu, u istom razdoblju poduzeća visoke tehnološke razine pridonijela su sa samo 12 %. Također, u drugoj polovici prošlog desetljeća u kontekstu zapošljavanja gotovo 12 % europske radne snage zaposleno je u industrijama niske tehnološke razine. Kada se govori isključivo o prerađivačima, ta se brojka povećava na gotovo dvije trećine svih zaposlenih. Naravno, postotak uvelike varira od zemlje do zemlje. Što se tiče Njemačke, u 2006. godini oko 50 % svih industrijskih radnika bilo je zaposleno u prerađivačkim sektorima niske tehnološke razine, a ti su sektori doprinijeli s gotovo 42 % ukupne industrijske dodane vrijednosti (Hirsch-Kreinsen, 2015).

Mannheim Innovation Panel

Za empirijsko testiranje hipoteza potrebni su podatci na razini poduzeća. Odgovarajući izvor podataka za svrhu istraživanja jesu službeni podatci o inovacijskoj aktivnosti njemačkih poduzeća pod nazivom Mannheim Innovation Panel (MIP). MIP uzorak jest stratificirani slučajni uzorak koji pokriva poduzeća s pet i više zaposlenih sa širokog područja ekonomskih aktivnosti. Od 1993. godine Centar za europska ekonomska istraživanja (Zentrum fuer Europaeische Wirtschaftsforschung – ZEW) godišnje prikuplja podatke o inovacijskoj aktivnosti njemačkoga gospodarstva, a originalni uzorak obuhvaćao je poduzeća iz različitih industrija, uključujući rudarstvo, prerađivačku industriju, energiju i vodne opskrbe, građevinarstvo te nekolicinu uslužnih djelatnosti (trgovinu na veliko, trgovinu nekretninama, IT, inženjerstvo i savjetovanje). U godinama 1995., 2001. i 2005. ubacivale su se i izbacivale pojedine djelatnosti, a trenutačno MIP obuhvaća 886 slojeva (stratuma): sve odjeljke iz područja B, C, D, E, H, J i K plus odjeljke 46, 69, 71, 72, 73, 74, 78, 79, 80, 81, 82 te skupinu 70.2, i to u osam „veličinskih” razreda mjereno po broju zaposlenih (5 do 9, 10 do 19, 20 do 49, 50 do 99, 100 do 249, 250 do 499, 500 do 999, 1000 i više) (Peters, Ramer, 2013). Istraživanje se provodi u ime BMBF-a (Saveznog ministarstva za obrazovanje i istraživanje) te u suradnji s

INFAS-om (Institut za primijenjenu društvenu znanost) i institutom Fraun-Hofer ISI (Institut za sustave i inovacijska istraživanja). MIP je njemački doprinos istraživanju Community Innovation Survey Europske komisije (CIS).

Upitnik

Iako je Mannheim Innovation Panel njemački doprinos CIS-u, MIP-ov anketni upitnik obuhvaća pitanja izvan standarda istraživanja Community Innovation Survey. Prednost je MIP-a u uključivanju pitanja o financijskim podacima jer Njemačka ne dozvoljava objedinjavanje podataka iz upitnika s podacima Državnog zavoda za statistiku. Nadalje, podatci o inovacijskoj aktivnosti poduzeća mnogo su detaljniji, npr. u mjerenju inovacija procesa gdje se kroz set pitanja teži boljem kvantificiranju ekonomskih utjecaja procesnih inovacija. Sva dodatna pitanja u MIP-ovu upitniku variraju tijekom vremena, a vođena su potrebama akademske zajednice i kreatora politika. Posljednjih godina dodatna inovacijska pitanja uključivala su: izvore financiranja inovacije, inovacijsku aktivnost u inozemstvu, izvore inovacija, ulogu marketinga u inovacijama, intelektualno vlasništvo, menadžment inovacija i inovacijskih projekata, utjecaj ekonomske krize na inovacijsku aktivnost i mnoge druge.

Originalni uzorak MIP-a iz 1993. godine obuhvaća 13 318 poduzeća, a nakon proširenja 1995. povećao se na 22 201 poduzeća (Peters, Ramer, 2013). Stopa povrata vrlo je niska ako se uspoređuje s CIS-om te se u prosjeku kreće oko 20 %. To se može pripisati neobvezujućoj, dobrovoljnoj formi ispunjavanja te dužem i složenijem upitniku. MIP je panel-upitnik, a uzorak poduzeća visoko je neuravnotežen „unbalanced” uzorak. Ukupan broj anketiranih poduzeća u razdoblju od 1993. do 2011. godine jest 97 432 poduzeća. Međutim, u 2011. godini samo je 12 % poduzeća, inicijalno anketiranih 1993., i dalje bilo dijelom uzorka, a samo 5,3 % poduzeća anketirano je od prve godine istraživanja (Peters, Ramer, 2013).

Uzorak DE NTP

Da bi se dobio uvid u inovacijske aktivnosti triju skupina njemačkih poduzeća niske i srednje niske tehnološke razine (DE NTP), uzorak je, kao i kod HR NTP, na temelju relevantne metodologije (Likar *et al.*, 2011) podijeljen na inovacijsko vodeća poduzeća, inovacijske sljedbenike i neinovativna poduzeća (tablica 15 i grafikon 6). Inovacijsko vodeća poduzeća

imaju udio prihoda od inovacija proizvoda u ukupnim prihodima viši od 20 %, dok im je udio prihoda od inovacija proizvoda novih za tržište u ukupnim prihodima od inovacija viši od 25 %. Skupina inovacijskih sljedbenika ima udio prihoda od inovacija proizvoda u ukupnim prihodima niži od 20 %, a udio prihoda od inovacija proizvoda novih za tržište u ukupnim prihodima od inovacija niži od 25 %. Skupina neinovativnih poduzeća nije prijavila prihod od inovacija u promatranom razdoblju (2008. – 2010.).

Ukupni uzorak i struktura njemačkih poduzeća niske i srednje niske tehnološke razine raspoređenih po inovacijskim skupinama unutar prerađivačkog sektora za razdoblje od 2008. do 2010. godine prikazana je na tablici 15 i grafikonu 6.


Tablica 15: Uzorak DE NTP

| | ukupni uzorak | neinovativna poduzeća (skupina 0) | inovacijski sljedbenici (skupina 1) | inovacijsko vodeći (skupina 2) |
|---|------------------|---|---|--------------------------------------|
| Njemačka poduzeća niske i srednje niske tehnološke razine (DE NTP) | 967 | 312 | 558 | 97 |

Izvor: Autor

Ukupni uzorak za potrebe istraživanja obuhvaća 967 srednje velikih i velikih prerađivačkih poduzeća niske i srednje niske tehnološke razine (DE NTP), od čega 97 poduzeća pripada inovacijsko vodećim poduzećima, 558 inovacijskim sljedbenicima, a 312 neinovativnim poduzećima.

Grafikon 6: Struktura DE NTP poduzeća u pogledu inovacijske aktivnosti




Napomena: Neinovativni ($RII = 0$, $RMI = 0$), inovacijski sljedbenici ($RII \leq 20$, $RMI \leq 25$) i inovacijsko vodeći ($RII > 20$, $RMI > 25$).

Izvor: Obrada autora prema podacima MIP-a 2011.

Iz grafikona 6 vidljivo je da u razdoblju 2008. – 2010. godine prevladava skupina poduzeća inovacijski sljedbenici ($RII \leq 20$, $RMI \leq 20$) s udjelom od 58 % u ukupnom uzorku svih srednje velikih i velikih njemačkih prerađivačkih poduzeća niske i srednje niske tehnološke razine (DE NTP). Udio neinovativnih poduzeća iznosi 32 %, dok je udio inovativno vodećih njemačkih poduzeća ($RII > 20$, $RMI > 25$) 10 %.

Na grafikonu 7 može se vidjeti struktura po djelatnostima njemačkih srednje velikih i velikih prerađivačkih poduzeća niske i srednje niske tehnološke razine. Uzorak od 967 poduzeća podijeljen je prema klasifikaciji NACE Rev 2.

Grafikon 7: Struktura DE NTP poduzeća po djelatnostima



Napomena: Neinovativni (RII = 0, RMI = 0), inovacijski sljedbenici (RII ≤ 20, RMI ≤ 25) i inovacijsko vodeći (RII > 20, RMI > 25).

Na ordinati (y-osi) prikazani su udjeli poduzeća.

Izvor: Obrada autora prema podacima MIP-a 2011.

Najveći broj ispitanih poduzeća nalazi se unutar djelatnosti C24 (proizvodnja metala) i C25 (proizvodnja gotovih metalnih proizvoda, osim strojeva i opreme izuzev C25.4 proizvodnja oružja i streljiva). Od 247 poduzeća (26 % uzorka), njih 148 (60 %) otpada na skupinu inovacijski sljedbenici, 82 (33 %) na neinovativna poduzeća, a 17 (7 %) na inovacijsko vodeća poduzeća. Sljedeća skupina poduzeća po brojnosti nalazi se unutar djelatnosti C10 (proizvodnja prehrambenih proizvoda), C11 (proizvodnja pića) i C12 (proizvodnja duhanskih proizvoda). Od 168 poduzeća (17 % uzorka), njih 92 (55 %) otpada na skupinu inovacijski sljedbenici, 63 (38 %) na neinovativna poduzeća, a 13 (8 %) na inovacijsko vodeća poduzeća. Djelatnosti C31 (proizvodnja namještaja), C32 (ostala prerađivačka industrija izuzev C32.5 (proizvodnja medicinskih i stomatoloških instrumenata i pribora)) i C33 (popravak i instaliranje strojeva i opreme) obuhvaćaju 166 poduzeća (17 % uzorka), od čega njih 104 (63 %) otpada na skupinu inovacijski sljedbenici, 48 (30 %) na neinovativna poduzeća, a 14 (8 %) na inovacijsko vodeća poduzeća.

Najmanji broj ispitanih poduzeća, njih 96 (10 %), nalazi se unutar djelatnosti C13 (proizvodnja tekstila), C14 (proizvodnja odjeće) i C15 (proizvodnja kože i srodnih proizvoda) te dok se unutar djelatnosti C23 (proizvodnja ostalih nemetalnih mineralnih proizvoda) nalazi 86 poduzeća, tj. 9 % ukupnog uzorka.

Empirijska analiza inovacijskih varijabli


U svrhu testiranja hipoteza (*H5-H7*) i pripadajućih pomoćnih hipoteza (*H5a – H5f*) iz podataka koje prikuplja Mannheim Innovation Panel za razdoblje 2008. – 2010. godine upotrijebit će se varijable koje opisuju produktivnost inovacijskog procesa, visinu i strukturu ulaganja DE NTP u inovacijske aktivnosti, zaposleni na poslovima R&D-ja, inovacijske sposobnosti poduzeća, uštede u troškovima i poboljšanja u kvaliteti te financijski pokazatelji.

H5: Na inovacijske rezultate DE NTP, osim ulaznih inovacijskih čimbenika (visina i struktura ulaganja u inovacije), ne utječu i procesni inovacijski čimbenici (organizacija i upravljanje inovacijskim procesom)

Ključni inovacijski ulazni čimbenik jest suma novca utrošena na inovacijske aktivnosti. Ukupni iznos inovacijskih aktivnosti kod njemačkih prerađivača i uslužnog sektora udvostručio se u razdoblju između 1995. i 2010. godine, sa 60,7 milijardi eura na 121,3 milijardi eura. Pod inovacijskim aktivnostima podrazumijevaju se trošak unutarnjeg (vlastitog) i vanjskog R&D-ja, troškovi za nabavu postrojenja, opreme, softvera i ostale nematerijalne imovine upotrijebljene za razvoj i predstavljanje inovacija proizvoda i procesa te troškova na osposobljavanje, marketing, dizajn i druge relevantne aktivnosti.

Produktivnost inovacijskog procesa definirana je kao odnos visine inovacijskih prihoda i za to namijenjenih financijskih ulaganja. Produktivnost će se prikazati kao omjer ukupnih prihoda od inovacija i ukupnih ulaganja u inovacije. Na grafikonu 8 može se vidjeti produktivnost inovacijskog procesa njemačkih prerađivačkih poduzeća niske tehnološke razine.

Grafikon 8: Produktivnost inovacijskog procesa DE NTP



Napomena: Neinovativni (RII = 0, RMI = 0), inovacijski sljedbenici (RII \leq 20, RMI \leq 25) i inovacijsko vodeći (RII $>$ 20, RMI $>$ 25).

Na ordinati (y-osi) prikazan je povrat na inovacijska ulaganja.

Izvor: Obrada autora prema podacima MIP-a 2011.

Inovacijsko vodeća poduzeća na jedan uloženi euro u inovacijske aktivnosti ostvaruju povrat u vidu prihoda od inovacija novih ili znatno poboljšanih proizvoda od 16,81 eura. Skupine inovacijski sljedbenici ostvaruju povrat od 12,60 eura, što je za 4,21 eura manje od inovacijsko vodećih poduzeća u promatranom razdoblju.

H5a: Ne postoji statistički značajna razlika u efikasnosti inovacijskog procesa inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP

S obzirom na razliku u ukupnom prosječnom povratu na inovacijska ulaganja, razumno je za pretpostaviti da postoji i statistički značajna razlika u produktivnosti inovacijskog procesa između skupina DE NTP. Da bi se provjerila ta pretpostavka, u nastavku će se primijeniti parametrijski ili neparametarski statistički testovi.

U skladu s istraživanjima koja su proveli Shapiro i Wilk (1965) te Razali i Wah (2011), vizualnim pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom ($p < 0,05$ te se može odbaciti hipotezu H_0 koja kaže da je distribucija podataka normalna) utvrdilo se da podaci za sve tri inovacijske skupine poduzeća DE NTP nisu normalno

distribuirani. Z-vrijednosti asimetrije i zaobljenosti izvan su intervala od -1,96 do 1,96, tj. *skewness* (koeficijent asimetrije) iznosi 2,804 (standardna greška (SE) 0,110), a *kurtosis* (koeficijent zaobljenosti) 9,087 (SE 0,219), što također potvrđuje odbacivanje pretpostavke o normalnoj distribuciji (Cramer, 1998; Cramer i Howitt, 2004; Doane i Seward, 2011). U tablici 16 prikazani su rezultati neparametrijskog testa o produktivnosti inovacijskog procesa.

Tablica 16: Mann-Whitneyjev test o produktivnosti inovacijskog procesa DE NTP

| | <i>Produktivnost procesa</i> | |
|------------------------|------------------------------|-----------|
| | (0 vs 2) ^a | (1 vs 2) |
| Mann-Whitney U | 0,000 | 10062,000 |
| Wilcoxon W | 2278,000 | 69747,000 |
| Z | -11,002 | -4,081 |
| Asymp. Sig. (2-tailed) | 0,000*** | 0,000*** |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

*** Signifikantnost na razini pouzdanosti od 99 %

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva testa potvrđuju postojanje razlike u produktivnosti inovacijskog procesa NTP. Navedeni je test statistički značajan. Signifikantnost testa kod skupina neinovativnih i inovacijsko vodećih poduzeća (0 vs 2) i kod skupina inovacijskih sljedbenika i inovacijsko vodećih HR NTP (1 vs 2) iznosi $p = 0,000$. Shodno tome, ovim testom nije dana potpora (odbacuje se) pomoćnoj hipotezi *H5a* te se može zaključiti da postoji statistički značajna razlika u produktivnosti inovacijskog procesa skupine inovacijsko vodećih poduzeća i skupina inovacijskih sljedbenika i neinovativnih HR NTP.

Prema Rammeru (2002), izdatci za istraživanje i razvoj u Njemačkoj su 2000. godine u inovacijskim izdancima iznosili 55 %. U 2010. godini kod prerađivačkih poduzeća niske tehnološke razine ulaganja u R&D nešto su niža te u ukupnom uzorku iznose 38,2 % ukupnih inovacijskih ulaganja.

Tablica 17: Udio ulaganja u R&D DE NTP


| | ulaganje u R&D / ukupna inovacijska ulaganja |
|-------------------------|--|
| Neinovativni | 33,72 % |
| Inovacijski sljedbenici | 40,30 % |
| Inovacijski vodeći | 37,71 % |
| ukupan uzorak | 38,20 % |

Izvor: Obrada autora prema podacima MIP-a 2011.

Tablica 17 prikazuje udio ulaganja u R&D DE NTP u ukupnim inovacijskim ulaganjima svih triju skupina poduzeća. Neinovativna prerađivačka poduzeća u promatranom su razdoblju iz ukupnih inovacijskih ulaganja izdvajala 33,72 % na istraživanje i razvoj, inovacijsko vodeća poduzeća 37,71 %, dok su najveći udio R&D ulaganja u ukupnoj strukturi inovacijskih ulaganja imali inovacijski sljedbenici s 40,30 %. Pod R&D ulaganjem smatra se udio istraživanja i razvoja koji provodi sama tvrtka te udio R&D-ja koji provode treće osobe. Nažalost, kod Mannheim Innovation Panela neke su vrijednosti „skraćene”, tj. „okrnjene”. U pojedinim slučajevima poduzeća mogu prikazati „ekstremne” intenzitete, npr. intenzitet istraživanja i razvoja (izdatci za R&D/prihod) iznosi 25 %. U takvim ekstremnim slučajevima vrijednosti su okrnjene (u pravilu se rijetko javljaju u populaciji) kako bi se spriječilo prepoznavanje poduzeća na temelju takva intenziteta. Na primjer, za intenzitet istraživanja i razvoja gornja je granica postavljena na 0,15. Drugim riječima, ako poduzeće ima intenzitet istraživanja i razvoja od 0,25, to je skraćeno/okrnjeno na 0,15.

Na grafikonu 9 mogu se vidjeti visina i struktura ulaganja DE NTP u inovacijske aktivnosti. Visina i struktura ulaganja još se može nazvati i inovacijskim intenzitetom, tj. udjelom ukupnih inovacijskih ulaganja u prihodima određenog poduzeća. Kao i kod ulaganja u R&D, u Mannheim Innovation Panelu neke su vrijednosti okrnjene, tj. gornja se granica nalazi na 0,35.

Grafikon 9: Visina i struktura ulaganja DE NTP u inovacijske aktivnosti



Napomena: Neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2.

Na ordinati (y-osi) prikazan je udio u ukupnim prihodima poduzeća.

Izvor: Obrada autora prema podacima MIP-a 2011.

Iz grafikona 9 vidi se da inovacijsko vodeća poduzeća ulažu najveći dio svojih prihoda u inovacijske aktivnosti, i to 3,67 %. Pritom 1,39 % otpada na izravna ulaganja u istraživanje i razvoj. Inovacijski sljedbenici izdvajaju 2,79 % svojih prihoda u inovacijska ulaganja, od čega 1,13 % otpada na R&D, dok neinovativna poduzeća ulažu 0,91 % svojih prihoda s udjelom od 0,31 % u R&D-ju. Prosječno gledano u ukupnom uzorku, DE NTP uložila su u razdoblju 2008. – 2010. godine 2,46 % svojih prihoda u inovacijske aktivnosti.

H5b: Ne postoji statistički značajna razlika u visini i strukturi inovacijskih ulaganja inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP

Da bi se i statistički provjerila značajna razlika u visini i strukturi inovacijskih ulaganja DE NTP, primijenit će se neparametrijski Mann-Whitneyjev test dvaju nezavisnih uzoraka. Vizualnim pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom ($p < 0,05$) pokazalo se da podatci za sve tri inovacijske skupine poduzeća DE NTP nisu normalno distribuirani. Z-vrijednosti asimetrije i zaobljenosti izvan su intervala od -1,96 do 1,96

tj. *skewness* (koeficijent asimetrije) 3,397 i 4,437 (standardna greška (SE) 0,090) i *kurtosis* (koeficijent zaobljenosti) od 15,696 i 22,307 (SE 0,180), što također potvrđuje odbacivanje pretpostavke o normalnoj distribuciji. Tablica 18 prikazuje razliku u rangovima u visini ukupnih ulaganja u inovacije te razliku ulaganja u istraživanje i razvoj inovacijsko vodećih i neinovativnih DE NTP.

Tablica 18: Mann-Whitneyjev test o visini i strukturi ulaganja inovacijsko vodećih i neinovativnih DE NTP

| | <i>Ukupna inov. ulaganja</i> | <i>Ulaganja u R&D</i> |
|-----------------------------|------------------------------|---------------------------|
| Mann-Whitney U ^a | 3642,500 | 5708,000 |
| Wilcoxon W | 34518,500 | 41754,000 |
| Z | -10,663 | -8,977 |
| Asymp. Sig. (2-tailed) | 0,000*** | 0,000*** |

^a Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI)

*** Signifikantnost na razini pouzdanosti od 99 %

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva testa potvrđuju razliku u visini ukupnih ulaganja u inovacije te razliku ulaganja u R&D inovacijsko vodećih i neinovativnih DE NTP. Navedeni test za obje je varijable statistički značajan na razini pouzdanosti od 99 %, tj. *p* vrijednost iznosi 0,000 te se može zaključiti da postoji statistički značajna razlika u visini ukupnih ulaganja i visini ulaganja u R&D inovacijsko vodećih u odnosu na skupinu neinovativnih DE NTP.

Tablica 19 prikazuje razliku u rangovima u visini ukupnih ulaganja u inovacije te razliku ulaganja u istraživanje i razvoj inovacijsko vodećih i inovacijskih sljedbenika DE NTP.

Tablica 19: Mann-Whitneyjev test o visini i strukturi ulaganja inovacijsko vodećih i inovacijskih sljedbenika DE NTP

| | <i>Ukupna inov. ulaganja</i> | <i>Ulaganja u R&D</i> |
|-----------------------------|------------------------------|---------------------------|
| Mann-Whitney U ^a | 16527,000 | 15167,500 |
| Wilcoxon W | 121638,000 | 115295,500 |
| Z | -3,320 | -2,922 |
| Asymp. Sig. (2-tailed) | 0,001*** | 0,003*** |

^a Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI)

*** Signifikantnost na razini pouzdanosti od 99 %


Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva testa potvrđuju razliku u visini ukupnih ulaganja u inovacije te razliku ulaganja u R&D između skupina inovacijsko vodećih poduzeća i inovacijskih sljedbenika. Navedeni je test za obje varijable statistički značajan na razini pouzdanosti od 99 % (*p* vrijednost iznosi 0,001 i 0,003) te se može zaključiti da postoji statistički značajna razlika u visini ukupnih ulaganja i visini ulaganja u R&D inovacijsko vodećih poduzeća u odnosu na skupinu inovacijskih sljedbenika DE NTP.

S obzirom na to da među trima promatranim skupinama postoji statistički značajna razlika u visini ukupnih ulaganja u inovacije i visini ulaganja u R&D, može se odbaciti pomoćna hipoteza *H5b* i zaključiti da postoji statistički značajna razlika u visini i strukturi inovacijskih ulaganja inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP.

U skladu s metodologijom OECD-a (2002), MIP upitnik, uz novčana ulaganja i inovacijske aktivnosti (R&D), tijekom određenog razdoblja prikuplja i podatke o zaposlenima na poslovima istraživanja i razvoja (intenziteta alokacije zaposlenika). Kako bi se spriječilo prepoznavanje poduzeća na temelju pokazatelja intenziteta alokacije zaposlenika (zaposlenici na poslovima R&D-ja / svi zaposleni), vrijednosti su nažalost okrnjene na 0,15 (vidjeti 107. str.). Na grafikonu 10 prikazana je prosječna ukupna zaposlenost u svim trima skupinama njemačkih poduzeća niske i srednje tehnološke razine razvijenosti.

Grafikon 10: Zaposlenici na poslovima R&D-ja DE NTP



Napomena: Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2).

Na ordinati (y-osi) prikazan je udio u ukupnom broju zaposlenih.

Izvor: Istraživanje autora

Grafikon 10 jasno prikazuje da je u 2010. godini najveći postotak zaposlenih na poslovima istraživanja i razvoja bio kod skupine inovacijsko vodećih DE NTP, njih 4,44 %. Inovacijski sljedbenici u prosjeku zapošljavaju 3,37 % zaposlenih, dok je najmanji broj zaposlenih na poslovima R&D-ja (1,05 %) kod neinovativnih DE NTP. Inovacijsko vodeća poduzeća u prosjeku imaju 31,75 % više zaposlenih na poslovima R&D-ja od inovacijskih sljedbenika i 322,86 % više od neinovativnih DE NTP.

H5c: Ne postoji statistički značajna razlika između DE NTP u postotku zaposlenika uključenih na poslove R&D

Razlika u ukupnom prosječnom postotku zaposlenika uključenih na poslove R&D-ja među trima promatranim skupinama upućuje na pretpostavku da postoji i statistički značajna razlika u broju zaposlenika na poslovima istraživanja i razvoja među skupinama DE NTP. Pregledom histograma, plotova, Shapiro-Wilkova testa ($p = 0,00$) te koeficijenta asimetrije od 2,042 (SE 0,095) i koeficijenta zaobljenosti od 4,484 (SE 0,190) pokazalo se da podatci za sve tri inovacijske skupine poduzeća DE NTP nisu normalno distribuirani te će se primijeniti neparametrijsko testiranje (tablica 20).

Tablica 20: Mann-Whitneyjev test o zaposlenima na poslovima R&D-ja DE NTP

| | <i>Zaposleni u R&D-ju</i> | |
|------------------------|-------------------------------|-----------|
| | (0 vs 2) ^a | (1 vs 2) |
| Mann-Whitney U | 2199,500 | 11452,000 |
| Wilcoxon W | 24144,500 | 79348,000 |
| Z | -10,473 | -3,311 |
| Asymp. Sig. (2-tailed) | 0,000*** | 0,001*** |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

*** Signifikantnost na razini pouzdanosti od 99 %

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva testa potvrđuju postojanje razlike u broju zaposlenika na poslovima R&D-ja DE NTP. Navedeni je test statistički značajan, a signifikantnost testa kod skupina neinovativnih i inovacijsko vodećih poduzeća (0 vs 2) iznosi $p = 0,000$, dok kod skupina inovacijskih sljedbenika i inovacijsko vodećih HR NTP (1 vs 2) iznosi $p = 0,001$. Shodno tome, ovim testom nije dana potpora (odbacuje se) pomoćnoj hipotezi $H5c$ te se može zaključiti da postoji statistički značajna razlika u postotku zaposlenika uključenih na poslove R&D-ja kod skupine inovacijsko vodećih poduzeća i skupina inovacijskih sljedbenika i neinovativnih HR NTP.

H5d: Ne postoji statistički značajna razlika u inovacijskim sposobnostima inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP

Mannheim innovation panel, osim ulaznih i izlaznih inovacijskih čimbenika i pokazatelja, prikuplja podatke i o procesnim aktivnostima poduzeća. U svakom promatranom razdoblju (3 godine) Mannheim Innovation Panel prikuplja podatke o različitim procesnim pokazateljima. U MIP 2011 prikupljeni su podatci o inovacijskim sposobnostima poduzeća. U nastavku slijedi prikaz 11 varijabli mjerenih ljestvicom od 1 do 5 (slabo do vrlo jako):

spos1 = praćenje kupčevih potreba

spos2 = razvoj novih tehničkih rješenja

spos3 = odobravanje slobode „pokušaja i pogreške”
spos4 = visoka individualna odgovornost zaposlenika
spos5 = kreativnost zaposlenika
spos6 = poticaji zaposlenicima za razvoj novih ideja
spos7 = promocija unutarnje suglasnosti među proizvodnim idejama
spos8 = interna suradnja među divizijama
spos9 = uključenje vanjskih partnera u projekt
spos10 = brza implementacija ideja sve do lansiranja na tržište
spos11 = brzo preuzimanje inovacija od drugih

Vizualnim pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom ($p < 0,05$ za svih 11 varijabli i može se odbaciti hipotezu H_0 koja kaže da je distribucija podataka normalna) pokazalo se da podatci za sve tri inovacijske skupine poduzeća DE NTP nisu normalno distribuirani. Z-vrijednosti asimetrije i zaobljenosti izvan su intervala od -1,96 do 1,96, tj. *skewness* (koeficijent asimetrije) od -0,626 do 0,380 (standardnom greška (SE) 0,086) i *kurtosis* (koeficijent zaobljenosti) od -0,639 do 0,630 (SE 0,172). Navedeno također potvrđuje odbacivanje pretpostavke o normalnoj distribuciji (Cramer, 1998; Cramer i Howitt, 2004; Doane i Seward, 2011).

S obzirom na to da se distribucija podataka značajno razlikuje od normalne distribucije, upotrijebljeni su Mann-Whitneyjevi neparametrijski testovi za utvrđivanje razlike u rangovima inovacijskih sposobnosti pojedinih skupina poduzeća. Tablica 21 prikazuje rezultate Mann-Whitneyjeva testa o inovacijskim sposobnostima skupina inovacijsko vodećih i inovacijski sljedbenika DE NTP.

Tablica 21: Mann-Whitneyjev test o inovacijskim sposobnostima inovacijsko vodećih i inovacijskih sljedbenika DE NTP

| | <i>spos1</i> | <i>spos2</i> | <i>spos3</i> | <i>spos4</i> | <i>spos5</i> | <i>spos6</i> |
|-----------------------------|--------------|--------------|--------------|--------------|--------------|--------------|
| Mann-Whitney U ^a | 20528,000 | 20511,500 | 18034,500 | 24323,000 | 22462,000 | 23669,500 |
| Wilcoxon W | 162839,000 | 161757,500 | 148850,500 | 165569,000 | 164773,000 | 163325,500 |
| Z | -2,853 | -2,816 | -2,978 | -0,251 | -1,902 | -0,582 |
| Asymp. Sig. (2-tail) | 0,004*** | 0,005*** | 0,003*** | 0,801 | 0,057* | 0,560 |

| | <i>spos7</i> | <i>spos8</i> | <i>spos9</i> | <i>spos10</i> | <i>spos11</i> |
|-----------------------------|--------------|--------------|--------------|---------------|---------------|
| Mann-Whitney U ^a | 20143,500 | 24008,000 | 22275,500 | 21970,500 | 23475,500 |
| Wilcoxon W | 155083,500 | 165786,500 | 162990,500 | 163748,500 | 162076,500 |
| Z | -2,677 | -0,837 | -1,548 | -2,165 | -0,651 |
| Asymp. Sig. (2-tail) | 0,007*** | 0,403 | 0,122 | 0,030** | 0,515 |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI)

*** Signifikantnost na razini pouzdanosti od 99 %; ** Signifikantnost na razini pouzdanosti od 95 %;

* Signifikantnost na razini pouzdanosti od 90 %.

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva U-testa potvrđuju postojanje razlike u rangovima pojedinih inovacijskih sposobnosti kod skupine inovacijsko vodećih poduzeća i inovacijskih sljedbenika DE NTP. Na razini značajnosti $\alpha = 0,01$ (1 %) navedeni je test statistički značajan (signifikantnost testa (p vrijednost) od 0,003 do 0,007) za varijable *spos1*, *spos2*, *spos3*, i *spos7*. Na razini značajnosti $\alpha = 0,05$ (5 %) test je statistički značajan za varijablu *spos10*, dok je na razini značajnosti $\alpha = 0,1$ (10 %) test statistički značajan za varijablu *spos5*. Inovacijsko vodeća DE NTP u odnosu na inovacijske sljedbenike više prate potrebe svojih kupaca, razvijaju nova tehnička rješenja te u inovacijskim aktivnostima pružaju veću slobodu u smislu „pokušaja i pogreški”. Također, uz nešto kreativnije zaposlenike, veći je naglasak na promociji unutarnje suglasnosti među proizvodnim idejama te bržoj implementaciji ideja sve do lansiranja na tržište.

Tablica 22 prikazuje rezultate Mann-Whitneyjeva testa o inovacijskim sposobnostima skupina inovacijsko vodećih i neinovativnih DE NTP.

Tablica 22: Mann-Whitneyjev test o inovacijskim sposobnostima inovacijsko vodećih i neinovativnih DE NTP

| | <i>spos1</i> | <i>spos2</i> | <i>spos3</i> | <i>spos4</i> | <i>spos5</i> | <i>spos6</i> |
|----------------------|--------------|--------------|--------------|--------------|--------------|--------------|
| Mann-Whitney U | 8345,500 | 7993,500 | 7813,500 | 11504,000 | 10241,000 | 11602,000 |
| Wilcoxon W | 44930,500 | 43444,500 | 40966,500 | 48360,000 | 46826,000 | 47380,500 |
| Z | -5,153 | -5,445 | -4,397 | -1,362 | -3,163 | -0,995 |
| Asymp. Sig. (2-tail) | 0,000*** | 0,000*** | 0,000*** | 0,173 | 0,002*** | 0,320 |

| | <i>spos7</i> | <i>spos8</i> | <i>spos9</i> | <i>spos10</i> | <i>spos11</i> |
|----------------------|--------------|--------------|--------------|---------------|---------------|
| Mann-Whitney U | 9309,000 | 11548,500 | 10139,500 | 9689,500 | 11081,500 |
| Wilcoxon W | 42720,000 | 47594,500 | 45917,500 | 45200,500 | 45534,500 |
| Z | -3,381 | -1,455 | -2,742 | -3,538 | -1,352 |
| Asymp. Sig. (2-tail) | 0,001*** | 0,146 | 0,006*** | 0,000*** | 0,176 |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI)

*** Signifikantnost na razini pouzdanosti od 99 %

Izvor: Istraživanje autora

Kao i u prethodnoj analizi, rezultati Mann-Whitneyjeva U-testa ukazuju na postojanje razlike u rangovima pojedinih inovacijskih sposobnosti kod skupine inovacijsko vodećih poduzeća i neinovativnih DE NTP. Na razini značajnosti $\alpha = 0,01$ (1 %) navedeni je test statistički značajan (signifikantnost testa od 0,000 do 0,006) za varijable *spos1*, *spos2*, *spos3*, *spos5*, *spos7*, *spos9* i *spos10*. Razlika u rangovima između inovacijsko vodećih poduzeća i neinovativnih DE NTP očituje su u istim varijablama kao i kod skupine inovacijsko vodećih i inovacijskih sljedbenika, uz razliku u uključenju vanjskih partnera u projekt. Unutar visine individualne odgovornosti zaposlenika, poticaja zaposlenicima za razvoj novih ideja te internoj suradnji među divizijama ne postoji statistički značajna razlika među svim trima promatranima skupinama poduzeća.

S obzirom na to da postoji natpolovična većina razlike u rangovima (6/11 i 7/11) inovacijskih sposobnosti poduzeća, skupine inovacijski vodećih poduzeća u odnosu na inovacijske sljedbenike i neinovativna poduzeća, može se zaključiti da ovim testovima nije dana potpora (odbacujemo) hipotezi *H5c* te da postoji statistički značajna razlika u inovacijskim sposobnostima inovacijsko vodećih poduzeća u odnosu na inovacijske sljedbenike i neinovativna njemačka poduzeća niske tehnološke razine.

H5e: Ne postoji statistički značajna razlika u prosječnim uštedama troškova inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP

Za razliku od standardiziranog upitnika u istraživanju Community Innovation Survey (CIS), MIP obuhvaća pokazatelje uspješnosti inovacija procesa. Nakon upita o uvođenju inovacija procesa, poduzećima se izravno postavlja pitanje jesu li te inovacije procesa dovele do smanjenja jediničnog troška u proizvodnji. Nakon potvrdnog odgovora, sljedeće pitanje odnosilo se procjenu²³ prosječne uštede troškova koju su potaknule inovacije procesa u referentnim godinama. S obzirom na to da se distribucija podataka značajno razlikuje od normalne distribucije (utvrđeno pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom), primijenjeni su Mann-Whitneyjevi neparametrijski testovi za utvrđivanje razlike u rangovima pojedinih skupina poduzeća. Tablica 23 prikazuje rezultate Mann-Whitneyjeva testa o prosječnim uštedama troškova inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP.

Tablica 23: Mann-Whitneyjev test o prosječnim uštedama troškova DE NTP

| | <i>Prosječna ušteda troškova</i> | |
|------------------------|----------------------------------|-----------|
| | (0 vs 2) ^a | (1 vs 2) |
| Mann-Whitney U | 2719,500 | 5738,500 |
| Wilcoxon W | 22819,500 | 34899,500 |
| Z | -7,668 | -2,375 |
| Asymp. Sig. (2-tailed) | 0,000 *** | 0,018*** |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

*** Signifikantnost na razini pouzdanosti od 95 %

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva testa potvrđuju postojanje razlike u prosječnoj uštedi troškova zbog inovacija procesa njemačkih NTP. Navedeni je test statistički značajan na razini od 1 % i kod inovacijsko vodećih poduzeća i kod skupine neinovativnih poduzeća (p vrijednost = 0,000)

²³ Procjena je mjerena skalom od 0 do 8 (intervali vrijednosti u % jesu 0 = 0, 1 = < 5, 2 = < 10, 3 = < 15, 4 = < 20, 5 = < 30, 6 = < 50, 7 = < 75 i 8 = ≤ 100)

te na razini od 5 % kod inovacijsko vodećih poduzeća i kod inovacijskih sljedbenika (p vrijednost = 0,018). S obzirom na navedeno, može se odbaciti hipoteza *H5d* i zaključiti da postoji statistički značajna razlika u prosječnoj uštedi troškova zbog inovacija procesa između inovacijsko vodećih i inovacijskih sljedbenika i neinovativnih njemačkih poduzeća niske tehnološke razine.

H5f: Ne postoji statistički značajna razlika u poboljšanjima u kvaliteti inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP

U domeni pokazatelja uspješnosti inovacija procesa, uz pitanja o prosječnim uštedama na troškovima, MIP upitnik obuhvaća i pitanja o poboljšanjima u kvaliteti koja su potakle inovacije procesa. Nakon filter-pitanja o poboljšanjima u kvaliteti (da/ne), od poduzeća je traženo da mjernom skalom (0 – 8)²⁴ ocijene koliko se povećao prihod poduzeća kao rezultat poboljšanja u kvaliteti koja su potaknule inovacije procesa. Tablica 24 prikazuje rezultate Mann-Whitneyjeva neparametrijskog testa o poboljšanjima u kvaliteti potaknutima inovacijom procesa. S obzirom na to da se distribucija podataka značajno razlikuje od normalne distribucije (utvrđeno pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom), primijenjeni statistički testovi prikladni su za utvrđivanje razlike u rangovima skupine inovacijsko vodećih poduzeća u odnosu na inovacijske sljedbenike i neinovativna DE NTP.

²⁴ Povećanje prihoda mjereno je skalom od 0 do 8 (intervali vrijednosti u % jesu 0 = 0, 1 = < 5, 2 = < 10, 3 = < 15, 4 = < 20, 5 = < 30, 6 = < 50, 7 = < 75 i 8 = ≤ 100)

Tablica 24: Mann-Whitneyjev test o poboljšanjima u kvaliteti DE NTP

| | <i>Poboljšanja u kvaliteti</i> | |
|------------------------|--------------------------------|-----------|
| | (0 vs 2) ^a | (1 vs 2) |
| Mann-Whitney U | 2098,500 | 4017,500 |
| Wilcoxon W | 21404,500 | 28107,500 |
| Z | -9,849 | -4,143 |
| Asymp. Sig. (2-tailed) | 0,000*** | 0,000*** |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

*** Signifikantnost na razini pouzdanosti od 99 %

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva testa potvrđuju postojanje razlike kod poboljšanja u kvaliteti zbog inovacija procesa DE NTP. Navedeni je test statistički značajan (signifikantnost testa jest kod 0 vs 2 0,000 i 1 vs 2 0,000). Ovim testom nije dana potpora (odbacuje se) hipotezi *H5e* te se može zaključiti da postoji statistički značajna razlika u poboljšanju kvalitete zbog inovacija procesa skupine inovacijsko vodećih poduzeća i skupina inovacijskih sljedbenika i neinovativnih njemačkih NTP.

U tablici 25 sažeto su prikazani rezultati testiranja pomoćnih hipoteza primjenom Mann-Whitneyjeva testa.

Tablica 25: Sažetak testiranja pomoćnih hipoteza primjenom Mann-Whitneyjeva testa

| Hipoteze | Rezultati |
|--|-------------|
| <i>H5a: Ne postoji statistički značajna razlika u efikasnosti inovacijskog procesa inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP</i> | Odbacuje se |
| <i>H5b: Ne postoji statistički značajna razlika u visini i strukturi inovacijskih ulaganja inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP</i> | Odbacuje se |
| <i>H5c: Ne postoji statistički značajna razlika između DE NTP u postotku zaposlenika uključenih na poslove R&D</i> | Odbacuje se |
| <i>H5d: Ne postoji statistički značajna razlika u inovacijskim sposobnostima inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP</i> | Odbacuje se |
| <i>H5e: Ne postoji statistički značajna razlika u prosječnim uštedama troškova inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP</i> | Odbacuje se |
| <i>H5f: Ne postoji statistički značajna razlika u poboljšanjima u kvaliteti inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP</i> | Odbacuje se |

Izvor: Autor

S obzirom na to da se primjenom Mann-Whitneyjeva testa testiralo i odbacilo svih šest pomoćnih hipoteza, također se može odbaciti i hipoteza *H5* te se može zaključiti da na inovacijske rezultate DE NTP, osim ulaznih inovacijskih čimbenika (visina i struktura ulaganja u inovacije), utječu i procesni inovacijski čimbenici (organizacija i upravljanje inovacijskim procesom).

H6: Ulazni inovacijski čimbenici DE NTP ne utječu značajno na procesne čimbenike DE NTP

Zbog odbacivanja hipoteze *H5* te zaključka da, uz ulazne inovacijske čimbenike, na inovacijske rezultate DE NTP utječu i „nefinancijski” procesni čimbenici, treba testirati postoji li između utjecajnih čimbenika statistički značajna veza. Kako između promatranih varijabli ne postoji linearna povezanost i neprekidna normalna distribucija (utvrđeno pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom), za opisivanje povezanosti između dvaju inovacijskih čimbenika, ulaznih (*inoinv*) i procesnih čimbenika (*spos1 - spos11*) njemačkih NTP primijenit će se Spearmanov koeficijent korelacije (produkt rang korelacije)

(tablica 26). Spearmanov koeficijent korelacije primijenit će se za mjerenje povezanosti između udjela ukupnih ulaganja u inovacije u prihodima DE NTP i 11 inovacijskih sposobnosti DE NTP.

Tablica 26: Korelacije između ulaznih i procesnih čimbenika DE NTP

| | | <i>spos1</i> | <i>spos2</i> | <i>spos3</i> | <i>spos4</i> | <i>spos5</i> | <i>spos6</i> |
|----------------------------|------------------|--------------|--------------|--------------|---------------|---------------|--------------|
| <i>inoinv</i> ^a | Spearman's r_s | -0,004 | 0,158 | 0,144 | -0,007 | 0,028 | 0,010 |
| | Sig. (2-tailed) | 0,971 | 0,143 | 0,198 | 0,948 | 0,795 | 0,925 |
| | N | 92 | 88 | 88 | 82 | 88 | 90 |
| | | <i>spos7</i> | <i>spos8</i> | <i>spos9</i> | <i>spos10</i> | <i>spos11</i> | |
| <i>inoinv</i> ^a | Spearman's r_s | 0,059 | -0,128 | 0,129 | 0,037 | -0,175 | |
| | Sig. (2-tailed) | 0,582 | 0,229 | 0,231 | 0,727 | 0,103 | |
| | N | 88 | 90 | 88 | 90 | 88 | |

Napomena: ^a Ukupna ulaganja u inovacije/prihod

Izvor: Istraživanje autora


Rezultati Spearmanove korelacije pokazuju da ne postoji statistički značajna povezanost između ulaznih inovacijskih čimbenika DE NTP i procesnih čimbenika DE NTP. Ulazni inovacijski čimbenici, tj. inovacijski intenziteti *inoinv* (udjeli ukupnih inovacijskih ulaganja u prihodima određenog poduzeća), ne koreliraju ni s jednim procesnim (nefinancijskim) čimbenikom, tj. ni s jednom od 11 inovacijskih sposobnosti promatranih poduzeća (*spos1* – *spos11*). Rezultati korelacijske analize u tablici 26 ne ukazuju na značajnu povezanost ($p > 0,05$) između inovacijskog intenziteta i praćenja kupčevih potreba ($p = 0,971$) kao ni: inovacijskog intenziteta i razvoja novih tehničkih rješenja ($p = 0,143$); inovacijskog intenziteta i odobravanja slobode „pokušaja i pogrešaka” ($p = 0,198$); inovacijskog intenziteta i visoke individualne odgovornosti zaposlenika ($p = 0,948$); inovacijskog intenziteta i kreativnosti zaposlenika ($p = 0,795$); inovacijskog intenziteta i poticaja zaposlenicima za razvoj novih ideja ($p = 0,925$); inovacijskog intenziteta i promocije unutarne suglasnosti među proizvodnim idejama ($p = 0,582$); inovacijskog intenziteta i interne suradnje među divizijama ($p = 0,229$); inovacijskog intenziteta i uključenja vanjskih partnera u projekt ($p = 0,231$); inovacijskog intenziteta i brze

implementacije ideja sve do lansiranja na tržište ($p = 0,727$) i inovacijskog intenziteta i brzog preuzimanja inovacija od drugih ($p = 0,103$). Može se zaključiti da je ovim testom dana potpora (prihvaćamo) hipotezi *H6* te da ulazni inovacijski čimbenici DE NTP ne utječu značajno na procesne čimbenike njemačkih prerađivačkih poduzeća niske i srednje niske tehnološke razine.

Financijski pokazatelji inovacijskih skupina

Kao što je navedeno i na početku poglavlja, Njemačka ne dozvoljava objedinjavanje podataka iz različitih upitnika s podacima Njemačkog državnog zavoda za statistiku. Velika prednost MIP baze jest u prikupljanju financijskih podataka unutar samog upitnika. Na grafikonu 11 prikazane su vrijednosti te kretanja prihoda i prihoda po zaposlenome u trogodišnjem razdoblju.

Grafikon 11: Prihod i prihod po zaposlenom DE NTP



Napomena: Podatci su okrnjeni ako je prihod/zaposleni > 0,6.

Na ordinati (y-osi) prikazan je prihod izražen u tisućama DM.

Izvor: Obrada autora

Prosječni prihod inovacijsko vodećih poduzeća DE NTP u razdoblju 2008. – 2010. iznosi 141,3 milijuna DM (1 euro = 1,98 DM), prihod inovacijskih sljedbenika 233,4 milijuna DM te prihod neinovativnih poduzeća NTP 73,4 milijuna DM. Promatrajući prihode, skupina inovacijskih sljedbenika izgleda prilično dominantno u sumi ukupnih prihoda. No slika se mijenja podijele li se prihodi poduzeća u razdoblju 2008. – 2010. s brojem zaposlenih.

Sve inovacijske skupine pokazuju slične trendove u razdoblju recesije. Na grafikonu 11 jasno je vidljiv negativan rast ukupnih prihoda kod svih skupina poduzeća. Zanimljivo je da je pad prihoda u 2009. godini najviše izražen kod inovacijsko vodećih poduzeća DE NTP (-15,1 %), dok su neinovativna poduzeća (-10,3 %) i inovacijski sljedbenici (-7,1 %) iskazali nešto manji pad. Očigledno je recesijska 2008. godina uzela danak kod inovacijsko aktivnijih poduzeća. U 2010. godini vidljiv je uzlet faze poslovnog ciklusa, inovacijsko vodeća poduzeća rasla su za 8 %, sljedbenici 1,8 %, a neinovativna poduzeća za čak 9,1 %. Kada se u kalkulaciju uvrste zaposlenici, vrijednosti se mijenjaju u korist skupine inovacijsko vodećih poduzeća koja su u razdoblju 2008. – 2010. po zaposleniku prosječno uprihodila 347.844 DM ostvarivši rast od 2,7 %. Inovacijski sljedbenici ostvarili su prosječan prihod po zaposlenome u iznosu od 340.356 DM, ali su im prihodi padali za 2,5 %, dok su neinovativna poduzeća ostvarila prosječan prihod po zaposlenome od 314.451 DM, s padom od 5 % u promatranom razdoblju.

Tablica 27: Financijski pokazatelji inovacijskih skupina DE NTP

| Pokazatelji | Ino. skupina | 2008 | 2009 | 2008/09 (%) | 2010 | 2009/10 (%) | 2008/10 (%) |
|--|--------------|--------------------|--------------------|--------------|--------------------|-------------|--------------|
| <i>Prihod od prodaje</i> | V | 150.771.856 | 130.942.784 | -15,14 | 142.255.773 | 7,95 | -5,99 |
| | S | 242.844.201 | 226.669.695 | -7,14 | 230.797.007 | 1,79 | -5,22 |
| | N | 76.848.429 | 69.653.654 | -10,33 | 76.619.231 | 9,09 | -0,30 |
| <i>Prihod od prodaje po zaposlenom</i> | V | 350.795 | 332.222 | -5,59 | 360.515 | 7,85 | 2,70 |
| | S | 351.815 | 325.865 | -7,96 | 343.387 | 5,10 | -2,45 |
| | N | 329.296 | 300.468 | -9,59 | 313.590 | 4,18 | -5,01 |

Napomena: V = inovacijsko vodeći, S = inovacijski sljedbenici, N = neinovativni

Izvor: Obrada autora prema podacima MIP-a 2011.

Financijski pokazatelji izraženi prihodom od prodaje i prihodom od prodaje po zaposlenome osciliraju iz godine u godinu, što se može povezati i s učincima financijske krize koja je

nastupila 2008. godine. U svakom slučaju, inovacijski sljedbenici iskazuju najveću apsolutnu vrijednost prihoda od prodaje koji je u padu u 2009. i 2010. u odnosu na 2008. godinu. Treba napomenuti da je prihod od prodaje uvjetovan potražnjom na tržištu i formiranjem cijena, ali i specifičnostima podskupina u prerađivačkoj industriji. Usporedba u pojedinoj industriji može imati različite karakteristike, ovisno o tome koliko je klasifikacija detaljna, dok je usporedba među poduzećima uvjetovana veličinom imovine i kapitala te kapitalizacijom tržišta (Muresan, Wolitzer, 2004).

Za dodatnu analizu značajnosti razlika u financijski izraženoj efikasnosti inovacijsko vodećih DE NTP u odnosu na inovacijske sljedbenike i neinovativna DE NTP u tablici 28 prikazane su vrijednosti i kretanja profitne marže (ROS) svih triju inovacijskih skupina poduzeća.

Tablica 28: Profitna marža inovacijskih skupina DE NTP

| Pokazatelji | Ino. skupina | 2009 | 2010 | 2010/09 (%) |
|-------------|--------------|--------------|--------------|--------------|
| <i>ROS</i> | V | 2,783 | 4,592 | 65,00 |
| | S | 3,579 | 4,144 | 15,79 |
| | N | 2,967 | 3,678 | 23,96 |

Napomena: V = inovacijsko vodeći, S = inovacijski sljedbenici, N = neinovativni

Izvor: Obrada autora prema podacima MIP-a 2011.

Vidljivo je da prema bitnom pokazatelju profitabilnosti, koji ukazuje na sposobnost zarađivanja, inovacijski vodeća poduzeća u 2010. godini dostižu stopu od 4,59 % zarade u odnosu na ostvarene prihode te uz najvišu relativnu i apsolutnu vrijednost značajno odstupaju od pratećih skupina poduzeća.

S obzirom na to da su financijski pokazatelji, koji se temelje na podacima o prihodima i profitnoj marži, prikazani agregirano za svaku inovacijsku skupinu poduzeća i uzimajući u obzir činjenicu da populaciju čine srednje velika i velika poduzeća, čiji pojedinačni pad ili rast može značajno utjecati na agregirane prosječne vrijednosti, u nastavku će se upotrebljavati parametrijski ili neparametrijski statistički test za procjenu statistički značajne razlika u financijski izraženoj efikasnosti svih poduzeća unutar DE NTP. Testiranje hipoteze *H7* izvršit će se na temelju pokazatelja prosječnog rasta (u promatranom razdoblju) svih triju financijskih pokazatelja.

H7: Ne postoji statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih DE NTP u odnosu na inovacijske sljedbenike i neinovativna DE NTP

Pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom ($p = 0,00$ za sve tri varijable) utvrđeno je da podatci inovacijskih skupina poduzeća DE NTP nisu normalno distribuirani sa z-vrijednostima asimetrije i zaobljenosti izvan intervala $-1,96 - 1,96$, tj. *skewness* (koeficijent asimetrije) od 0,389 do 1,822 (standardnom greška (SE) 0,093) i *kurtosis* (koeficijent zaobljenosti) od 0,728 do 17,485 (SE 0,185). S obzirom na to da se distribucija podataka značajno razlikuje od normalne distribucije, za testiranje razlike u rangovima financijske efikasnosti inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015 upotrijebljen je Mann-Whitneyjev neparametrijski test (tablice 29 i 30).

Tablica 29: Mann-Whitneyjev test o financijskoj efikasnosti inovacijsko vodećih i neinovativnih DE NTP

| | <i>Prihod_avg_g</i> | <i>Prihod po zaposlenom_avg_g</i> | <i>ROS_g</i> |
|------------------------|---------------------|-----------------------------------|--------------|
| Mann-Whitney U | 13849,000 | 8285,000 | 7360,000 |
| Wilcoxon W | 62677,000 | 44870,000 | 33011,000 |
| Z | -1,262 | -4,016 | -2,738 |
| Asymp. Sig. (2-tailed) | 0,207 | 0,000*** | 0,006*** |

Napomena: Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI); *_avg_g* = prosječan rast; *g* = rast

*** Signifikantnost na razini pouzdanosti od 99 %.

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva U-testa potvrđuju ono što je vidljivo iz grafikona 11 i tablica 27 i 28, odnosno postojanje razlike u rangovima financijskih pokazatelja inovacijsko vodećih i neinovativnih DE NTP. Kod prosječnog rasta u prihodima test nije statistički značajan. Međutim, na razini značajnosti $\alpha = 0,01$ (1 %) navedeni je test statistički značajan (signifikantnost testa iznosi 0,000 i 0,006) kod sljedećih dvaju pokazatelja, prosječnom rastu prihoda po zaposlenom i rastu profitne marže.

U nastavku su prikazani rezultati Mann-Whitneyjeva testa o razlikama u rangovima financijskih pokazatelja inovacijsko vodećih u odnosu na inovacijske sljedbenike DE NTP.

Tablica 30: Mann-Whitneyjev test o financijskoj efikasnosti inovacijsko vodećih i inovacijskih sljedbenika DE NTP

| | <i>Prihod_avg_g</i> | <i>Prihod_po zaposlenom_avg_g</i> | <i>ROS_g</i> |
|------------------------|---------------------|---------------------------------------|--------------|
| Mann-Whitney U | 23268,000 | 15322,000 | 14328,000 |
| Wilcoxon W | 177558,000 | 141073,000 | 110031,000 |
| Z | -2,132 | -4,293 | -2,823 |
| Asymp. Sig. (2-tailed) | 0,033** | 0,000*** | 0,005*** |

Napomena: Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI); *_avg_g* = prosječan rast; *g* = rast

*** Signifikantnost na razini pouzdanosti od 99 %; ** Signifikantnost na razini 95 %

Izvor: Istraživanje autora

Iz grafikona 11 i tablica 27 i 28 nije bilo vidljivo postojanje značajne statističke razlike u financijskim pokazateljima inovacijsko vodećih i inovacijskih sljedbenika DE NTP. Rezultati Mann-Whitneyjeva U-testa potvrđuju da je navedeni test statistički značajan na razini značajnosti $\alpha = 0,01$ i $\alpha = 0,05$ (1 % i 5 %) kod svih triju pokazatelja, prosječnom rastu prihoda, prosječnom rastu prihoda po zaposlenom i rastu profitne marže.

Ovim neparametrijskim testovima nije dana potpora (odbacuje se) hipotezi *H7* te se može zaključiti da postoji statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih DE NTP u odnosu na inovacijske sljedbenike i neinovativna DE NTP.

4.5. Faza 3 – Istraživanje na primarnim podacima hrvatskih poduzeća s niskom i srednje niskom tehnološkom razinom (HR NTP 2015) (H8 do H13)

Svrha istraživanja u trećoj fazi ovog rada je da se uz pomoć primarnih i sekundarnih podataka hrvatskih poduzeća s niskom i srednje niskom razinom tehnološke razvijenosti istraži mogućnost cjelovitog i uspješnog upravljanja inovacijama na temelju predloženog modela prijelaza iz neinovativnog u inovativno vodeće poduzeće. U prvoj i drugoj fazi istraživanja istaknuti su čimbenici povezani s inovacijskim rezultatima poduzeća koji pružaju čvrsti temelj za daljnju analizu inovacijske aktivnosti poduzeća:

- utvrđena je povezanost između visine i strukture ulaganja u inovacije i rezultata inovacija u hrvatskim poduzećima s niskom i srednje niskom tehnološkom razinom
- utvrđena je povezanost između inovacijskih rezultata i gospodarske efikasnosti hrvatskih poduzeća s niskom i srednje niskom tehnološkom razinom
- istražena je međusobna povezanost pokazatelja inovacijskih ulaganja, pokazatelja upravljanja inovacijskim procesom i inovacijskih rezultata njemačkih poduzeća s niskom i srednje niskom tehnološkom razinom
- utvrđena je povezanost između inovacijskih rezultata i gospodarske efikasnosti njemačkih poduzeća s niskom i srednje niskom tehnološkom razinom

Empirijska istraživanja teorijskih pretpostavki na 996 HR NTP u prvoj i 967 DE NTP u drugoj fazi sadrže i određene ograničavajuće čimbenike:

- podaci prve faze istraživanja na hrvatskim poduzećima niske i srednje niske tehnološke razine obuhvaćaju razdoblje 2010-2012,
- podaci iz druge faze istraživanja na njemačkim poduzećima niske i srednje niske tehnološke razine odnose se na razdoblje 2008-2010,
- u prvoj fazi istraživanja uključeni su isključivo financijski inovacijski čimbenici, ne i nefinancijski tj. procesni,
- u drugoj fazi istraživanja analizirana su isključivo njemačka poduzeća niske i srednje niske tehnološke razine.

S obzirom na gore navedene ograničavajuće čimbenike za generalizaciju rezultata, uz pomoć recentnih primarnih i sekundarnih podataka u trećoj fazi istraživanja izvršit će se daljnja analiza

inovacijskih aktivnosti poduzeća. Također, usporedit će se rezultati s njemačkim poduzećima i istražiti da li je moguć prijenos znanja na srednje velika i velika hrvatska poduzeća niske i srednje niske tehnološke razine.

Područje istraživanja i metoda prikupljanja podataka

Kao glavna metoda prikupljanja primarnih podataka u trećoj fazi empirijskog istraživanja upotrijebljen je anketni upitnik²⁵. Primarni podatci odnose se na inovacijske aktivnosti poduzeća za razdoblje od 2013. do 2015. godine. Upitnik je najčešće primjenjivana metoda prikupljanja primarnih kvalitativnih i kvantitativnih podataka kod mjerenja inovacijske aktivnosti poduzeća. Visokostrukturirani upitnik sastavljen je i analiziran na temelju pregleda relevantne literature i prethodnih istraživanja te se sastoji od standardnog oblika zatvorenih pitanja, otvorenih pitanja, dihotomnih pitanja, pitanja uz primjenu ordinalne i omjerne ljestvice te Likertove skale s ocjenama od 1 do 7. Upitnik je za potrebe istraživanja napravljen u *online* obliku s pomoću aplikacije otvorenog koda za izradu, provođenje i analizu *online* anketa pod nazivom *1ka*. Upotreba na domeni www.1ka.si besplatna je i bez ikakvih ograničenja. Sekundarni financijski podatci za razdoblje od 1.1.2013. do 1.1.2017. godine zatraženi su od hrvatske Financijske agencije (FINA). Spajanjem primarnih podataka iz inoviranog upitnika i sekundarnih podataka pokušat će se utvrditi postoji li pozitivna veza između inovacijske i financijske efikasnosti hrvatskih poduzeća niske i srednje niske tehnološke razine.

Prije formalnog prikupljanja podataka provedeno je pretestiranje (pilot-testiranje) u obliku osobnog intervjua s deset menadžera visoke razine srednje velikih i velikih prerađivačkih poduzeća. Pilot-testiranje vođeno je jednako kao i glavno istraživanje te je kao takvo osmišljeno za procjenu osnovnog oblika razumljivosti i za otkrivanje slabosti i problema upitnika s kojima bi se ispitanici mogli susresti u masovnijem istraživanju. Stoga, kako bi se provjerilo jesu li ispitanici jasno razumjeli pitanja i utvrdilo jesu li potrebne daljnje izmjene stavki i formata, od menadžera intervjuiranih u njihovim organizacijama tražilo se da na anketni upitnik, uz odgovore, dodaju i povratne informacije o dizajnu i tekstu mjernog instrumenta istraživanja.

²⁵ Primjer anketnog upitnika s pomoću kojeg su prikupljeni podatci dostupan je na zahtjev.

Kao rezultat pilot-testiranja i na temelju intervjua, revidirani su i izmijenjeni pojedini sadržaji pitanja. Takav prerađeni anketni upitnik označio je završetak procesa kreiranja mjernog instrumenta istraživanja.

Struktura anketnog upitnika

Upitnik na hrvatskom jeziku sastoji se od ukupno 35 pitanja podijeljenih u 10 cjelina (120 varijabli), a procijenjeno vrijeme njegova ispunjavanja iznosi 18 minuta i 37 sekundi. U uvodu *online* upitnika i u porukama e-pošte koje su sadržavale poveznicu na *online* upitnik ispitanicima su predstavljeni svrha i ciljevi istraživanja te su još jednom upoznati s dobrovoljnim i anonimnim karakterom upitnika, uz podsjetnik da će podatci biti analizirani agregatno (pojedinačni identiteti uklonjeni). Nakon uvodnog dijela upitnik je strukturiran na sljedeći način:

- u prvom dijelu mjernog instrumenta trima se pitanjima, u skladu s metodologijom INOV (CIS) obrasca Državnog zavoda za statistiku, ispituje inovacijska aktivnost poduzeća u pogledu fizičkih proizvoda i usluga,
- drugi dio upitnika odnosi se na udio inoviranih i nepromijenjenih proizvoda i usluga u ukupnim prihodima poduzeća u 2015. godini. Također, u drugom dijelu upitnika, u skladu s INOV metodologijom, upotrijebljeno je pet tvrdnji kako bi se ispitali trošak inovacijskih aktivnosti poduzeća u 2015. godini te primitak bilo kojeg oblika financijske potpore za inovacijske aktivnosti u razdoblju 2013. – 2015.,
- treći dio upitnika sadržava šest pitanja (11 tvrdnji) o inovacijama procesa. Pitanja obuhvaćaju uvođenje i razvoj inovacija procesa u promatranom razdoblju te smanjenje prosječne cijene proizvoda proizvedene tim procesima kao i prosječno smanjenje troškova zbog tehnoloških inovacija procesa. Tvrdnje su preuzete iz INOV i MIP obrazaca.,
- u četvrtom dijelu upitnika, u skladu s INOV metodologijom, ispituju se organizacijske inovacije,
- u petom dijelu, u skladu s INOV metodologijom, ispituju se marketinške inovacije,
- u šestom dijelu upitnika od ispitanika se traži da rangiraju inovacije među strateškim prioritetima te da se izjasne u pogledu inovacije poslovnog modela tijekom zadnjih pet

godina. Također, u skladu s istraživanjem koje su proveli Andrew *et al.*, (2010), trima pitanjima utvrđuju se investicije u inovacije u sljedećoj godini, način na koji se mjeri uspjeh inovacije u poduzeću i koje su najveće prepreke pri inoviranju. Nadalje, u šestom se djelu mjernim instrumentom utvrđuju inovacijske sposobnosti poduzeća s pomoću 34 tvrdnje. Ispitanici su tvrdnje ocjenjivali na Likertovoj ljestvici sa sedam ocjena, pri čemu krajnje mjere glase „U potpunosti se ne slažem” (1) i „U potpunosti se slažem” (7),

- sedmi dio upitnika odnosi se na pitanja o strukturi uprave poduzeća i zaduženjima za inovacije i tehnologiju,
- osmi dio se odnosi na postotak visokoobrazovanih zaposlenika zaduženih na poslovima istraživanja i razvoja,
- deveta cjelina ispituje učinkovitost metoda za održavanje ili povećanje konkurentnosti inovacija proizvoda i procesa,
- deseta cjelina odnosi se na kontaktne podatke ispitanika.

Veličina uzorka

Istraživanje je provedeno na srednje velikim i velikim hrvatskim prerađivačkim poduzećima niske tehnološke razine (HR NTP)²⁶. Anketni upitnik u elektroničkom je obliku poslan na 308 adresa (poduzeća), a vraćeno je 97 ispunjenih upitnika. Od njih 97, 22 upitnika uklonjena su iz uzorka zbog nepotpunih ili pogrešno popunjenih tvrdnji. Završni uzorak sastojao se od 75 anketnih upitnika (cjelovito popunjenih) koji su dalje upotrebljavani za statističku analizu. Stopa odgovora iznosila je dakle 24,4 %. Treba napomenuti da su u svakom poduzeću podatci prikupljeni od jednog ispitanika.

Slanju anketnih upitnika u elektroničkom obliku prethodio je terenski rad u obliku polustrukturiranih intervju s menadžerima visoke razine (predsjednici uprave, članovi uprave, direktori kontrolinga, direktori sektora istraživanja i razvoja itd.). Cjelokupan proces intervjuiranja i anketiranja odvijao se od rujna 2016. do travnja 2017. godine. Osobno je posjećeno 37 odabranih srednje velikih i velikih HR NTP, dok je u 38 poduzeća intervju

²⁶ Klasifikacija djelatnosti u potpoglavlju 4.1.3.

obavljen telefonskim putem. Prosječno trajanje intervjua iznosilo je 47 minuta i 32 sekunde. Nakon kratke osobne komunikacije o ciljevima i svrsi istraživanja, ispitanicima je objašnjena složenija terminologija samog upitnika te se raspravilo o temama koje nisu obuhvaćene upitnikom, a unutar su samog područja istraživanja. Osigurana je anonimnost ispitanika, a u zahvalu za suradnju ponuđen je sažet izvještaj rezultata istraživanja. U ostatak odabranih poduzeća upitnik je poslan elektroničkom poštom nakon telefonskog informiranja. S osnovnom svrhom dubljeg razumijevanja situacije u kojoj se nalaze srednje velika i velika prerađivačka poduzeća niske tehnološke razine, provedeni polustrukturirani intervjui u konačnici su doprinijeli boljoj učinkovitosti i djelotvornosti naknadne obrade podataka.

Anketnim upitnikom prikupljeni su podaci o inovacijskoj aktivnosti HR NTP, a prema metodologiji primijenjenoj i u prvim dvjema fazama (Likar *et al.*, 2011), određene su medijske vrijednosti pokazatelja RII (udio prihoda od inovacija proizvoda u ukupnim prihodima, 20 %) i RMI (udio prihoda od inovacija proizvoda novih za tržište u ukupnim prihodima od inovacija, 25 %) te su poduzeća podijeljena u tri inovacijske skupine (tablica 31). Definirane skupine poduzeća jesu neinovativna poduzeća (RII = 0, RMI = 0), inovacijski sljedbenici (RII ≤ 20, RMI ≤ 25) i inovacijsko vodeća poduzeća (RII > 20, RMI > 25).

Tablica 31: Uzorak HR NTP 2015


| | ukupni uzorak | neinovativna poduzeća (skupina 0) | inovacijski sljedbenici (skupina 1) | inovacijsko vodeći (skupina 2) |
|---|------------------|---|---|--------------------------------------|
| Hrvatska poduzeća niske i srednje niske tehnološke razine (HR NTP 2015) | 75 | 16 | 36 | 23 |

Izvor: Autor

Ukupni uzorak za potrebe istraživanja obuhvaća 75 srednje velikih i velikih prerađivačkih poduzeća niske i srednje niske tehnološke razine (NTP), od čega 23 poduzeća pripadaju inovacijsko vodećim, 36 inovacijskim sljedbenicima, a 16 neinovativnim poduzećima. Na

grafikonu 12 vidljiva je struktura poduzeća u pogledu inovacijske aktivnosti od 2013. do 2015. godine.

Grafikon 12: Struktura HR NTP 2015




Napomena: Neinovativni (RII = 0, RMI = 0), inovacijski sljedbenici (RII \leq 20, RMI \leq 25) i inovacijsko vodeći (RII $>$ 20, RMI $>$ 25).

Izvor: Obrada autora prema podacima iz upitnika

Iz grafikona se vidi da u razdoblju 2013. – 2015. godine najveći udio (48 %) u ukupnom uzorku imaju inovacijski sljedbenici (RII \leq 20, RMI \leq 25), dok inovativno vodeća poduzeća (RII $>$ 20, RMI $>$ 25) sudjeluju s 31 %. Najslabije su zastupljena neinovativna poduzeća (RII = 0, RMI = 0), sa samo 21 %. U odnosu na prvu fazu istraživanja (vidjeti poglavlje 4.2.), znatno se razlikuje struktura NTP. Visok udio inovativnih poduzeća u strukturi u promatranom razdoblju može se pripisati relativno malom uzorku u odnosu na prvu fazu istraživanja ili činjenici da su HR NTP u procesu stabilizacije nakon kriznog razdoblja pojačali svoju inovacijsku aktivnost.

Nakon razdiobe HR NTP 2015 po inovacijskoj aktivnosti u promatranom razdoblju, na grafikonu 13 vidi se distribucija odgovora inovacijskih skupina na pitanje o važnosti inovacija u domeni strateškog prioriteta.

Grafikon 13: Inovacija kao strateški prioritet



Napomena: Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2).

Na ordinati (y-osi) prikazan je broj poduzeća.

Izvor: Istraživanje autora

Na pitanje „Kako rangirate inovacije među svojim strateškim prioritetima u poduzeću?” 17,4 % inovacijsko vodećih poduzeća izjasnilo se da su im inovacije glavni strateški prioritet, što je slučaj kod samo 5 % inovacijskih sljedbenika i kod nijednog neinovativnog poduzeća. Inovacije su među prvim trima strateškim prioritetima kod 65,2 % inovacijsko vodećih poduzeća i 55,5 % sljedbenika, dok su inovacije mjesto među deset strateških prioriteta pronašle kod čak 62,5 % neinovativnih poduzeća u promatranom razdoblju.

4.5.1. Ulazni inovacijski čimbenici HR PNT 2015


Za testiranje osme hipoteze upotrijebljeni su podaci prikupljeni anketnim upitnikom koji opisuju visinu i strukturu ulaganja HR NTP 2015 u inovacijske aktivnosti. U skladu s metodologijom OECD-a (i metodologijom u drugoj fazi istraživanja), dva ulazna pokazatelja

po kojima se inovacijske aktivnosti poduzeća mogu mjeriti jesu novčano ulaganje u R&D tijekom određenog razdoblja te zaposlenici koji rade na poslovima R&D-ja.

H8: Ne postoji statistički značajna razlika u ulaznim inovacijskim čimbenicima unutar skupina HR NTP 2015

Metodologija i struktura varijabli sukladna je prvoj fazi istraživanja (poglavlje 4.3., str. 96.). Ulazni inovacijski čimbenici u 2015. godini podrazumijevaju troškove poduzeća za vlastite aktivnosti istraživanja i razvoja, troškove poduzeća za vanjske usluge istraživanja i razvoja, troškove poduzeća za nabavu postrojenja, opreme, softvera i zgrada, troškove poduzeća za nabavu postojećeg znanja od drugih poduzeća ili organizacija i troškove poduzeća za sve ostale inovacijske aktivnosti, uključujući dizajn, osposobljavanje, marketing i druge relevantne aktivnosti. Na grafikonu 14 prikazane su visina i struktura ulaganja za sve tri inovacijske skupine srednje velikih i velikih prerađivačkih poduzeća niske i srednje niske tehnološke razine (HR NTP 2015), inovacijsko vodeća poduzeća, inovacijski sljedbenici i neinovativna poduzeća.

Grafikon 14: Visina i struktura ulaganja u inovacijske aktivnosti HR NTP 2015



Napomena: Neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2.

Na ordinati (y-osi) prikazan je udio u ukupnim prihodima poduzeća.

Izvor: Obrada autora prema podacima iz upitnika

Iz grafikona 14 jasno je vidljivo da u 2015. godini po visini i strukturi ulaganja u inovacijske aktivnosti prednjače inovacijsko vodeća HR NTP (3,52 % svojih prihoda). Inovacijski sljedbenici uložili su 1,89 %, a neinovativna poduzeća 2,68 % svojih prihoda. U prosjeku, HR NTP su 2015. godini uložili 2,70 % svojih prihoda u inovacijske aktivnosti, što je značajan porast u odnosu na 2012. godinu (0,33 % prihoda). Mogući razlozi značajnog porasta ulaganja u inovacijske aktivnosti HR NTP u samo tri godine mogu se prvotno pronaći u veličini i strukturi uzorka (75 poduzeća, a od toga 52 % inovacijsko aktivnih), ali i možebitno u pristupanju Republike Hrvatske Europskoj uniji (1. srpnja 2013.), postupnom izlasku iz recesije te poticajnim mjerama, tj. primljenim financijskim potporama HR NTP. Promatrajući strukturu ulaganja HR NTP u 2015. godini, većinom se ulaže u nabavu postrojenja, opreme, softvera i zgrada (*RMACX*), 2,02 % prihoda u ukupnom uzorku ili, u samoj strukturi inovacijskih ulaganja 74,78 %, te se može pretpostaviti da se takvim investicijama značajnije potiču procesne inovacije u odnosu na inovacije proizvoda. Zanimljivo je napomenuti da neinovativna poduzeća svoja inovacijska ulaganja u cijelosti ulažu u prije spomenutu kategoriju (99,74 %). Struktura ulaganja skupine inovativno vodećih poduzeća jest sljedeća: 63,76 % inovacijskih ulaganja otpada na nabavu postrojenja, opreme, softvera i zgrada, 17,11 % u vlastite aktivnosti istraživanja i razvoja (*RRDINX*), 8,82 % za sve ostale inovacijske aktivnosti, uključujući dizajn, osposobljavanje, marketing i druge relevantne aktivnosti (*ROTRX*), 7,12 % u vanjske usluge istraživanja i razvoja (*RRDEXX*) i 3,18 % za nabavu postojećeg znanja od drugih poduzeća ili organizacija (*ROEKX*). Kod skupine poduzeća inovacijski sljedbenici 59,97 % inovacijskih ulaganja otpada na nabavu postrojenja, opreme, softvera i zgrada, 32,65 % ulaže se u vlastite aktivnosti istraživanja i razvoja, 2,87 % u sve ostale inovacijske aktivnosti, uključujući dizajn, osposobljavanje, marketing i druge relevantne aktivnosti, 2,40 % u vanjske usluge istraživanja i razvoja i 2,11 % za nabavu postojećeg znanja od drugih poduzeća ili organizacija. Zaključno, prema grafikonu 14, može se zaključiti da se visinom i strukturom inovacijskih ulaganja inovacijsko vodeća poduzeća razlikuju od ostalih skupina HR NTP 2015.

Iz grafikona 14 ne vidi se distribucija odgovora na upit o primitku bilo kojeg oblika financijske potpore za inovacijske aktivnosti poduzeća u razdoblju 2013. – 2015. (uključujući financijsku potporu u obliku odbitaka na već plaćene stavke ili olakšice, nepovratna sredstva, subvencionirane zajmove ili zajmovne garancije, a isključujući istraživačke i druge inovacijske

aktivnosti koje su se potpuno provodile za javni sektor). Ne postoji velika razlika u broju primljenih financijskih potpora u tri skupine poduzeća (26,09 % inovacijsko vodećih, 25 % inovacijskih sljedbenika i 25 % neinovativnih poduzeća).

S obzirom na prosječnu visinu i strukturu inovacijskih ulaganja, razumno je za pretpostaviti da postoji statistički značajna razlika u visini inovacijskih ulaganja među skupinama HR NTP 2015. Da bi se pretpostavka provjerila, tj. da bi se testirale pomoćne hipoteze, u nastavku će se primijeniti parametrijski ili neparametarski statistički testovi.

H8a: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP 2015

Vizualnim pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom ($p = 0,00$ te možemo odbaciti hipotezu H_0 koja kaže da je distribucija podataka normalna) pokazalo se da podatci za sve tri inovacijske skupine poduzeća HR NTP nisu normalno distribuirani sa z-vrijednostima asimetrije i zaobljenosti izvan intervala $-1,96 - 1,96$, tj. *skewness* (koeficijent asimetrije) od 8,394 (standardnom greška (SE) 0,277) i *kurtosis* (koeficijent zaobljenosti) od 71,750 (SE 0,548). S obzirom na to da se distribucija podataka značajno razlikuje od normalne distribucije, primijenjeni su Mann-Whitneyjevi neparametrijski testovi za utvrđivanje razlike u rangovima promatranih skupina poduzeća. Tablica 32 prikazuje rezultate Mann-Whitneyjeva testa o visini inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP u 2015. godini.

Tablica 32: Mann-Whitneyjev test o visini inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP 2015

| | <i>ukupna inovacijska ulaganja/prihod</i> |
|-----------------------------|---|
| Mann-Whitney U ^a | 114,000 |
| Wilcoxon W | 250,000 |
| Z | -1,999 |
| Asymp. Sig. (2-tailed) | 0,046** |

^a Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI)

** Signifikantnost na razini pouzdanosti od 95 %

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva U-testa potvrđuju ono što je iz grafikona 14 jasno vidljivo, a to je postojanje razlike u rangovima ukupnih inovacijskih ulaganja HR NTP 2015. Na razini značajnosti $\alpha = 0,05$ (5 %), navedeni je test statistički značajan (signifikantnost testa je 0,046). Ovim testom nije dana potpora (odbacuje se) pomoćnoj hipotezi (H8a) te se može zaključiti da postoji statistički značajna razlika u visini inovacijskih ulaganja između skupine inovacijsko vodećih poduzeća i skupine neinovativnih HR NTP 2015. U 2015. godini inovacijsko vodeća poduzeća više su i raznovrsnije ulagala svoja sredstva u odnosu na skupinu neinovativnih hrvatskih poduzeća niske i srednje niske tehnološke razine.

H8b: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP 2015

Kako se distribucija podataka razlikuje od normalne distribucije (utvrđeno pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom), za utvrđivanje statistički značajne razlike u visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP 2015 također je upotrijebljen Mann-Whitneyjev neparametrijski test. Tablica 33 prikazuje rezultate Mann-Whitneyjeva testa.

Tablica 33: Mann-Whitneyjev test o visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP 2015

| | <i>ukupna inovacijska ulaganja/prihod</i> |
|-----------------------------|---|
| Mann-Whitney U ^a | 342,000 |
| Wilcoxon W | 342,000 |
| Z | -1,999 |
| Asymp. Sig. (2-tailed) | 0 ,263 |

^a Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI)


Izvor: Istraživanje autora

Navedeni Mann-Whitneyjev test nije statistički značajan (signifikantnost testa je 0,263) i rezultati testa ne mogu potvrditi postojanje razlike u rangovima ukupnih inovacijskih ulaganja HR NTP 2015. Ovim testom dana je potpora (prihvaća se) pomoćnoj hipotezi (H8b) te se može

zaključiti da ne postoji statistički značajna razlika u visini inovacijskih ulaganja skupine inovacijsko vodećih poduzeća i inovacijskih sljedbenika HR NTP 2015.

Nakon statističkog testiranja visine ulaganja HR NTP 2015, na grafikonu 15 prikazana je usporedna analiza visine ulaganja u inovacijske aktivnosti hrvatskih i njemačkih poduzeća niske i srednje niske tehnološke razine iz svih triju istraživačkih faza: 2010., 2012. i 2015. godine. Primarni i sekundarni podatci o inovacijskim ulaganjima potrebni za usporedbu prikupljeni su vlastitim upitnikom, Mannheim Innovation Panelom (MIP) i obrascem Inovacijske aktivnosti poduzeća (INOV).

Grafikon 15: Usporedba visine ulaganja NTP u inovacijske aktivnosti



Napomena: Neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2.


Na ordinati (y-osi) prikazan je udio u ukupnim prihodima poduzeća.

Izvor: Obrada autora prema podacima iz upitnika, MIP-a i INOV obrasca

Iz grafikona je prilično očigledan velik porast u inovacijskim ulaganjima HR NTP, što na određeni način i pojašnjava strukturu HR NTP 2015 (poglavlje 4.4., grafikon 12). Hrvatska prerađivačka poduzeća u ukupnom su uzorku 2015. godine uložila 2,70 % svojih prihoda, što je za 2,37 % više nego prosječno ulaganje svih poduzeća iz uzorka u 2012. godini. Njemačka poduzeća u 2010. godini prosječno su ulagala 2,46 % svojih prihoda, što je za 0,24 % manje od HR NTP 2015. Međutim, vidljivo je da njemačka inovacijsko vodeća poduzeća i pogotovo

inovacijski sljedbenici ulažu veća sredstva u inovacijske aktivnosti od hrvatskih poduzeća, što u konačnici upućuje na to da su razliku u korist HR NTP 2015 napravila neinovativna poduzeća koja su 2,68 % svojih prihoda gotovo u cijelosti uložila u nabavu postrojenja, opreme, softvera i zgrada. Stvari na njihovo mjesto (s obzirom na poziciju Njemačke prema inovacijskim pokazateljima) pomalo vraća grafikon 16 na kojemu se unutar inovacijskih ulaganja uspoređuje visina ulaganja prerađivačkih poduzeća u istraživanje i razvoj. Pod R&D ulaganjem smatra se udio istraživanja i razvoja koji provodi sama tvrtka te udio vanjskih usluga istraživanja i razvoja. Također, važno je za napomenuti da se analizirani podatci njemačkih NTP odnose na razdoblje u jeku financijske i ekonomske krize (2008. – 2010.), a određene vrijednosti kod Mannheim Innovation Panela okrnjene su na 25 %.

Grafikon 16: Usporedba visine ulaganja NTP u R&D



Napomena: Neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2.

Na ordinati (y-osi) prikazan je udio u ukupnim prihodima poduzeća.

Izvor: Obrada autora prema podacima iz upitnika, MIP-a i INOV obrasca


Iz grafikona 16 jasno je da sve tri promatrane skupine njemačkih NTP prosječno najveći dio svojih prihoda ulažu u istraživačko-razvojne aktivnosti, 0,94 % (38,20 % ukupnih inovacijskih ulaganja), dok HR NTP 2015 ulažu 0,51 % (18,88 % ukupnih inovacijskih ulaganja) što je za 0,43 postotna poena manje od DE NTP. U 2012. godini hrvatska su poduzeća u R&D prosječno ulagala neznatnih 0,09 % svojih prihoda, što je 27,27 % ukupnih inovacijskih ulaganja. Na izravna ulaganja u istraživanje i razvoj inovacijsko vodeća DE NTP ulažu 1,39 % svojih

prihoda, što je 63,53 % više nego HR NTP 2015 (0,85 % prihoda) i visokih 595 % više od HR NTP 2012 (0,20 % prihoda). Njemačka skupina inovacijski sljedbenici izdvaja 1,13 % svojih prihoda u istraživačko-razvojne aktivnosti, što je 71,21 % više od HR NTP 2015 (0,66 % prihoda) i čak 2160 % više od inovacijskih sljedbenika HR NTP 2012. (0,05 % prihoda). Njemačka neinovativna poduzeća uložila su u 2010. godini 0,31 % svojih prihoda u R&D aktivnosti, čak 0,11 postotnih poena više od skupine inovacijsko vodećih poduzeća HR NTP 2012, što potvrđuje potrebu za izravnim ulaganjima u R&D, a ne samo u nabavu postrojenja, opreme, softvera i zgrada.

H8c: Ne postoji statistički značajna razlika između HR NTP 2015 u postotku zaposlenika uključenih na poslove R&D

U skladu s metodologijom OECD-a (2002), spomenutom u najavi osme hipoteze, uz novčano ulaganje u R&D tijekom određenog razdoblja, drugi ulazni pokazatelj jesu zaposlenici koji rade na poslovima R&D-ja. Uključene su sve osobe zaposlene izravno na R&D-ju te one osobe koje pružaju izravne usluge, npr. R&D menadžeri, administratori i uslužno osoblje. Grafikon 17 prikazuje rezultate zaposlenosti na poslovima istraživanja i razvoja HR NTP za 2014. i 2015. godinu.

Grafikon 17: Zaposlenici na poslovima R&D-ja HR NTP 2015



Napomena: Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2).

Na ordinati (y-osi) prikazan je udio u ukupnom broju zaposlenih.

Izvor: Istraživanje autora

Grafikon jasno prikazuje da je u 2014. i u 2015. godini najveći postotak zaposlenih na poslovima istraživanja i razvoja bio kod skupine inovacijsko vodećih HR NTP 2015, 6,86 % zaposlenih u 2014. i 8,10 % u 2015. Inovacijski sljedbenici u prosjeku zapošljavaju 4,85 % (u 2014.) i 5,15 % zaposlenih (u 2015.) na poslove istraživanja i razvoja, dok je najmanji broj zaposlenih na poslovima R&D-ja u neinovativnim HR NTP 2015. Također, jedino kod skupine neinovativnih poduzeća primjetan je pad postotka zaposlenih od 10 %, dok je kod ostale dvije skupine poduzeća u dvije promatrane godine zabilježen rast zaposlenih na poslovima R&D-ja, i to 6 % kod skupine inovacijskih sljedbenika i 18 % kod inovacijsko vodećih HR NTP 2015. S obzirom na prosječnu vrijednost pokazatelja iz grafikona x, razumno je za pretpostaviti da postoji statistički značajna razlika između skupina poduzeća. Da bi se ta pretpostavka provjerila, u nastavku će se primijeniti parametrijski ili neparametarski statistički test, ovisno o samoj distribuciji podataka.

Kao i kod prethodne dvije pomoćne hipoteze, vizualnim pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom ($p = 0,00$) pokazalo se da podatci za sve tri inovacijske skupine poduzeća HR NTP nisu normalno distribuirani sa z-vrijednostima asimetrije i zaobljenosti izvan intervala $-1,96 - 1,96$, tj. *skewness* (koeficijent asimetrije) od 2,346 (standardnom greška (SE) 0,287) i *kurtosis* (koeficijent zaobljenosti) od 6,299 (SE 0,566). S obzirom na to da se distribucija podataka značajno razlikuje od normalne distribucije, primijenjeni su Mann-Whitneyjevi neparametrijski testovi za utvrđivanje razlike u rangovima pojedinih skupina poduzeća. Tablica 34 prikazuje usporednu analizu postotka zaposlenika uključenih na poslove istraživanja i razvoja hrvatskih poduzeća niske i srednje niske tehnološke razine za godinu 2015.

Tablica 34: Mann-Whitneyjev test zaposlenika uključenih na poslove R&D-ja HR NTP 2015

| | zaposleni u R&D-ju | |
|------------------------|-----------------------|----------|
| | (0 vs 2) ^a | (1 vs 2) |
| Mann-Whitney U | 76,000 | 322,500 |
| Wilcoxon W | 154,500 | 952,500 |
| Z | -2,170 | -1,281 |
| Asymp. Sig. (2-tailed) | 0,030** | 0,200 |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

** Signifikantnost na razini pouzdanosti od 95 %. Izvor: Istraživanje autora

Rezultati u tablici upućuju na statistički značajnu razliku u postotku zaposlenika uključenih na poslove istraživanja i razvoja između skupine inovacijsko vodećih HR NTP i skupine neinovativnih HR NTP. Navedeni test statistički je značajan na razini značajnosti $\alpha = 0,05 \%$, a signifikantnost testa iznosi 0,030. Nasuprot tome, između skupina inovacijsko vodećih HR NTP i inovacijskih sljedbenika HR NTP ne postoji statistički značajna razlika u postotku zaposlenika uključenih na poslove R&D-ja. Mann-Whitneyjev test nije statistički značajan, a signifikantnost testa iznosi 0,200 na razini pouzdanosti od 95 %. Ovim testom djelomično odbacujemo pomoćnu hipotezu *H8c* i može se zaključiti da postoji statistički značajna razlika u postotku zaposlenika uključenih na poslove istraživanja i razvoja između skupine inovacijsko vodećih HR NTP i skupine neinovativnih HR NTP, dok između skupina inovacijsko vodećih HR NTP i inovacijskih sljedbenika HR NTP ne postoji statistički značajna razlika.

U tablici 35 sažeto su prikazani rezultati testiranja pomoćnih hipoteza primjenom Mann-Whitneyjeva testa.

Tablica 35: Sažetak testiranja pomoćnih hipoteza

| Hipoteze | Rezultati |
|---|------------------------|
| <i>H8a: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP 2015</i> | Odbacuje se |
| <i>H8b: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP 2015</i> | Prihvća se |
| <i>H8c: Ne postoji statistički značajna razlika između HR NTP 2015 u postotku zaposlenika uključenih na poslove R&D</i> | Djelomično se odbacuje |


Izvor: Autor

Primjenom Mann-Whitneyjeva testa testirane su sve tri pomoćne hipoteze. S obzirom na različite rezultate neparametrijskih testiranja pomoćnih hipoteza, hipoteza *H8* može se djelomično odbaciti i može se zaključiti da između skupina inovacijsko vodećih i inovacijskih sljedbenika HR NTP 2015 ne postoji statistički značajna razlika u ulaznim inovacijskim čimbenicima, dok unutar skupina inovacijsko vodećih i neinovativnih HR NTP 2015 statistički značajna razlika u ulaznim inovacijskim čimbenicima postoji.

Visokoobrazovani zaposlenici i troškovi za stručno usavršavanje

Znanja i kompetencije zaposlenika čimbenici su koji statistički značajno utječu na inovacije (Guan, Ma, 2003). Velikom je broju poduzeća nedostatak visokoobrazovanoga i stručnog kadra najozbiljnija prepreka u procesu stvaranja inovacije i razvoju inovacijskih aktivnosti jer se oni, kako navode Martensen *et al.*, (2007) i Østergaard *et al.*, (2008), smatraju glavnim pokretačima inovacijskih aktivnosti s velikim utjecajem na inovacijske rezultate. Na grafikonu 18 nalaze se rezultati o stručnoj spremi zaposlenika svih triju skupina poduzeća za 2014. i 2015. godinu. Stručna sprema mjeri se postotkom zaposlenika s visokim obrazovanjem (završen diplomski sveučilišni studij, specijalistički diplomski stručni studij, preddiplomski, diplomski, integrirani preddiplomski i diplomski studij, poslijediplomski specijalistički i poslijediplomski sveučilišni studij ili, prema „starom” programu, završen stručni, sveučilišni ili magistarski studij ili postignut doktorat).

Grafikon 18: Postotak visokoobrazovanih zaposlenika HR NTP 2015



Napomena: Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

Na ordinati (y-osi) prikazan je udio u ukupnom broju zaposlenih.


Izvor: Istraživanje autora

Rezultati iz grafikona upućuju na veliku razliku u postotku zaposlenika s visokim obrazovanjem između inovativnih i neinovativnih poduzeća za 2014. i 2015. godinu. Postotak zaposlenika s

visokim obrazovanjem u ukupnom broju zaposlenika kod inovacijsko vodećih HR NTP 2015 u 2015. godini iznosio je 20,71 %, što je za 8 % više u odnosu na 2014. godinu. Postotak zaposlenika s visokim obrazovanjem kod skupine inovacijskih sljedbenika u 2015. godini iznosio je 17,52 % (uz rast od 3 %), dok je zamjetno niži udio visokoobrazovanih kod skupine neinovativnih HR NTP 2015, samo 6,93 %. Možemo zaključiti da inovativno vodeća poduzeća imaju viši postotak zaposlenika s visokim obrazovanjem u ukupnom broju zaposlenika (s tendencijom rasta) od ostalih HR NTP 2015, što, u skladu s rezultatima istraživanja Østergaard *et al.*, (2008), implicira pozitivnu vezu s inovacijskim rezultatima poduzeća.

Udio troškova za stručno usavršavanje u ukupnim troškovima zaposlenika u 2014. i 2015. godini prikazan je na grafikonu 19.

Grafikon 19: Troškovi za stručno usavršavanje HR NTP 2015



Napomena: Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2).

Na ordinati (y-osi) prikazan je udio u ukupnim troškovima zaposlenika.

Izvor: Istraživanje autora


Iz grafikona je vidljivo da su najveći prosječni udio troškova za stručno usavršavanje u ukupnim troškovima zaposlenika u 2014. i 2015. godini imali inovacijski sljedbenici. Udio troškova za stručno usavršavanje kod skupine inovacijskih sljedbenika u 2015. godini iznosio je 3,83 % (uz

rast od 15 % u odnosu na 2014.). Kod inovacijsko vodećih HR NTP 2015 u 2015. godini udio troškova iznosio je 2,94 %, što je za 14 % više u odnosu na 2014. godinu. Zamjetna je razlika u prosječnom udjelu troškova za stručno usavršavanje u ukupnim troškovima zaposlenika u 2014. i 2015. između inovativnih i neinovativnih poduzeća. Poduzeća iz skupine neinovativnih HR NTP 2015 u stručno usavršavanje svojih zaposlenika uložila se skromnih 1,40 %, uz nezamjetan rast od 5 %.

Produktivnost inovacijskog procesa

Kao i u prve dvije faze istraživanja, produktivnost inovacijskog procesa definirana je kao odnos visine inovacijskih prihoda i za to namijenjenih financijskih ulaganja te se mjeri kao omjer ukupnih prihoda od inovacija i ukupnih ulaganja u inovacije. Na grafikonu 20 prikazana je produktivnost inovacijskog procesa hrvatskih prerađivačkih poduzeća niske i srednje niske tehnološke razine za 2015. godinu.

Grafikon 20: Produktivnost inovacijskog procesa HR NTP 2015



Napomena: Neinovativni (RII = 0, RMI = 0), inovacijski sljedbenici (RII ≤ 20, RMI ≤ 25) i inovacijsko vodeći (RII > 20, RMI > 25).

Na ordinati (y-osi) prikazan je povrat na inovacijska ulaganja.

Izvor: Obrada autora


Inovacijsko vodeća poduzeća na jednu uloženu kunu u inovacijske aktivnosti ostvaruju povrat u vidu prihoda od inovacija novih ili znatno poboljšanih proizvoda od visokih 71,32 kune.

Skupina inovacijski sljedbenici ostvaruje povrat od 42,82 kune, što je za 29,50 kuna manje od inovacijsko vodećih poduzeća u promatranom razdoblju.

Buduća ulaganja u inovacijske aktivnosti

U skladu s istraživanjem koje su proveli Andrew *et al.*, (2010), inovirani upitnik u trećoj fazi istraživanja utvrđuje investicije poduzeća u inovacijske aktivnosti tijekom sljedeće godine. Distribucija odgovora ispitanika na pitanje „Koliko planirate investirati u inovacije u sljedećoj godini, uspoređujući s proteklom godinom?” prikazana je na grafikonu 21.

Grafikon 21: Investicije u inovacije u sljedećoj godini



Napomena: Na ordinati (y-osi) prikazan je broj poduzeća.

Izvor: Obrada autora

Rezultati iz grafikona upućuju na zamjetnu razliku u planiranim investicijama u inovacijske aktivnosti između skupina HR NTP 2015. Čak 34,78 % inovacijsko vodećih poduzeća (8/23) u nadolazećoj godini planira povećati svoje investicije u inovacije za više od 10 %, što je znatna razliku u odnosu na 13,29 % inovacijskih sljedbenika (5/36) i 6,25 % neinovativnih NTP (1/16). Neznatno povećanje ulaganja najzastupljenije je kod skupine inovacijskih sljedbenika gdje

44,44 % poduzeća planira ulagati od 1 % do 10 % svojih prihoda u inovacijske aktivnosti. U istom intervalu istu odluku izrazio je 21,74 % inovacijsko vodećih poduzeća te 12,50 % neinovativnih. Zabrinjava visok udio iste dinamike ulaganja neinovativnih HR NTP 2015. Iznimno visokih 81,25 % poduzeća planira otprilike ista ulaganja. Kod skupina inovacijsko vodećih i inovacijskih sljedbenika (39,13 % i 41,67 %) taj je udio znatno niži, što dvostruko ohrabruje s obzirom na sadašnju inovacijsku aktivnost.

4.5.2. Procesni čimbenici inovacijske aktivnosti HR NTP 2015

Eksploratorna faktorska analiza i analiza pouzdanosti

Da bi se ispitaio utjecaj nefinancijskih, procesnih čimbenika na inovacijsku aktivnost HR NTP 2015, primijenjene su metode multivarijatne analize, faktorska analiza i analiza pouzdanosti. Multivarijatna analiza obuhvaća statističke metode kojima se istodobno analizira međusobna povezanost više od dviju varijabli. Za potrebe racionalizacije mjernih ljestvica upotrijebljena je eksploratorna faktorska analiza (exploratory factor analysis) kojom je reduciran velik broj elemenata inovacijskih sposobnosti na manji broj zajedničkih čimbenika koji opisuju i objašnjavaju njihovu međusobnu povezanost. Osnovni cilj provođenja eksploratorne faktorske analize u ovom radu jest racionalizacija broja varijabli pokazatelja, tj. da se iz postojećih elemenata inovacijskih sposobnosti prerađivačkih poduzeća pokušaju kreirati manje grupe međusobno povezanih elemenata, čimbenika (dimenzija), koji najbolje opisuju inovacijske sposobnosti prerađivačkih poduzeća niske i srednje niske tehnološke razine. Također, ovaj postupak osigurava da su mjerne ljestvice valjane i pouzdane prije testiranja hipoteza. U analizama je upotrijebljen statistički paket za obradu podataka IBM SPSS (statistički paket za društvene znanosti – *Statistical Package for Social Science*), verzija 23.

Jedan je od ciljeva ovog rada empirijski testirati postoji li razlika u različitim inovacijskim sposobnostima poduzeća niske i srednje niske tehnološke razine te analizirati stupanj važnosti svake dimenzije inovacijske sposobnosti u kreiranju inovacijskog outputa. S obzirom na to da ne postoje konsenzus ni jasna metodološka preporuka u domeni mjerenja inovacijskih sposobnosti, postoji potreba za vlastitim dizajnim seta tvrdnji nefinancijskog karaktera. Za formuliranje i odabir tvrdnji, kasnije upotrijebljenih u eksploratornoj faktorskoj analizi, iscrpno

je i detaljno pregledana literatura, tj. prijašnja istraživanja iz ciljanog područja. Odabrane tvrdnje dodane su inovacijskim sposobnostima koje su empirijski analizirane u drugoj fazi istraživanja (Mannheim Innovation Panel, 2011) te je zaključno predložen skup od 35 pokazatelja inovacijskih sposobnosti poduzeća (tablica 36).

Tablica 36: Skupina pokazatelja inovacijskih sposobnosti

| Inovacijske sposobnosti | Tvrdnje | Odabrane referencije |
|--|---|---|
| Sposobnost strateškog upravljanja | Inovacijska strategija ugrađena u korporativnu strategiju i planove te potiče razvoj novih ideja. Tehnologija usklađena s poslovnim ciljevima i strategijom. Definiran sustav pokazatelja uspješnosti koji potiče inovacije kroz sustav nagrađivanja. Uspješno upravljanje intelektualnim kapitalom. U procesu upravljanja inovacijom praćenje, analiziranje i ocjenjivanje rezultata. Razvijen sustav poboljšanja i unapređenja proizvoda/usluga (npr. benchmarking). Povezivanjem s drugima smanjen rizik i troškovi inovacija. | Porter (1980) Utterback (1982) Twiss (1986) Prahalad i Hamel (1990) Hall (1992) Chiesa <i>et al.</i> (1996) Neely i Bourne (2000) Lawson i Samson (2001) Guan i Ma (2003) Yam <i>et al.</i> (2004) Subramaniam i Youndt (2005) Martensen <i>et al.</i> (2007) Cockburn <i>et al.</i> (2010) Likar <i>et al.</i> (2011) Singh i Rao (2016) |
| Organizacijska sposobnost | Paralelno upravljanje s više inovacijskih projekata. Fleksibilno prilagođavanje organizacijske strukture novim inovacijskim projektima. Brza reakcija i prilagodba zahtjevima vanjskog okruženja. Dobra koordinacija i suradnja između R&D, marketing i proizvodnog odjela. Visok stupanj autonomije nižeg menadžmenta | Hayes i Wheelwright (1984) Teece <i>et al.</i> (1997) Eisenhardt i Martin (2000) Lawson i Samson (2001) Danneels (2002) Guan i Ma (2003) Mann (2005) Hansen i Birkinshaw (2007) Ambrosini <i>et al.</i> (2009) Yam <i>et al.</i> (2010) |

| Inovacijske sposobnosti | Tvrdnje | Odabrane referencije |
|---|--|---|
| Istraživačko-razvojna (R&D) sposobnost | <p>R&D plan povezan s poslovnim planom poduzeća i tehnološkim kompetencijama.</p> <p>Brza i kvalitetna povratna informacija proizvodnog odjela.</p> <p>Dobra komunikacija s marketinškim odjelom.</p> <p>Sustavno praćenje trendova o budućim i tehnologijama u nastajanju (FET).</p> <p>Razvijanje novih tehnoloških rješenja.</p> | <p>MIP (2011)</p> <p>Berry i Taggart (1998)</p> <p>Guan i Ma (2003)</p> <p>Lyne (2003)</p> <p>Yam <i>et al.</i> (2004)</p> <p>Koc i Ceylan (2007)</p> <p>Yam <i>et al.</i> (2010)</p> <p>MIP (2011)</p> <p>Love i Roper (2015)</p> |
| Sposobnost upotrebe resursa | <p>Važnost pri zapošljavanju, razvoju, ocjenjivanju i nagrađivanju svojih zaposlenika.</p> <p>Sustavna financijska potpora inovacijskoj aktivnosti.</p> <p>Odgovornost zaposlenika.</p> <p>Kreativnost zaposlenika.</p> <p>Poticanje zaposlenika na razvoj novih ideja.</p> <p>Brza implementacija ideje sve do lansiranja na tržište.</p> <p>Mogućnost brzog preuzimanja inovacije od drugih.</p> | <p>Twiss (1986)</p> <p>Wheelwright i Clark (1992)</p> <p>Kaufmann i Toling (2002)</p> <p>Guan i Ma (2003)</p> <p>Evans i Wolf (2005)</p> <p>Subramaniam i Youndt (2005)</p> <p>Hunteret <i>et al.</i> (2007)</p> <p>Alpkan <i>et al.</i> (2010)</p> <p>Yam <i>et al.</i> (2010)</p> <p>MIP (2011)</p> <p>Chang <i>et al.</i> (2012)</p> |
| Proizvodna sposobnost | <p>Proizvodni proces podešen u skladu sa zahtjevima R&D procesa.</p> <p>Proizvodni odjel uključen u ranu fazu razvoja novog proizvoda.</p> <p>Visoka tehnološka razina proizvodne opreme.</p> <p>Primjena ključnih naprednih tehnologija</p> <p>Zaposlenici s visokom operativnom razinom sposobnosti upravljanja proizvodnom opremom.</p> | <p>Wheelwright i Clark (1992)</p> <p>Swink i Hegarty, (1998)</p> <p>Boyer i Lewis, (2002)</p> <p>Sheather (2002)</p> <p>Guan i Ma (2003)</p> <p>Hanna (2007)</p> <p>Koc i Ceylan (2007)</p> <p>Yam <i>et al.</i> (2010)</p> <p>Terjesen <i>et al.</i> (2011)</p> |
| Informacijska i marketinška sposobnost | <p>Dugoročni odnosi s kupcima s ciljem razumijevanja njihovih različitih zahtjeva.</p> | <p>Bailetti i Litva (1995)</p> <p>Chesbrough (2003)</p> <p>Guan i Ma (2003)</p> |

| Inovacijske sposobnosti | Tvrdnje | Odabrane referencije |
|-------------------------|--|---|
| | Marketinškim aktivnostima povećan tržišni udio. | Yam <i>et al.</i> (2004) Laursen i Salter (2006) |
| | Kvalitetna usluga nakon prodaje. | Song <i>et al.</i> (2007) |
| | Upravljanje i kontrola distribucijske mreže. | Nath <i>et al.</i> (2010) |
| | Pouzdana isporuka u dogovorenom roku. | Yam <i>et al.</i> (2010) |
| | Učinkovito predviđanje promjene u kupčevim preferencijama. | MIP (2011) |

Izvor: Istraživanje autora

Inovacijske sposobnosti poduzeća ispitanici ocjenjuju Likertovom ljestvicom od sedam ocjena (od 1 – u potpunosti se ne slažem do 7 – u potpunosti se slažem). Jedna od pretpostavki za primjenu faktorske analize jest mjerenje podataka na intervalnoj ljestvici. U literaturi ne postoji konsenzus o tome mogu li se pojedinačni Likertovi podatci smatrati podacima na razini intervala ili se trebaju tretirati kao ordinalni podatci (Norman, 2010). Prema nekim autorima, ordinalna se ljestvica može smatrati intervalnom ako se polazi od pretpostavke da su intervali na ljestvici jednaki (Raspor, 2012). Dobra postavljena Likertova ljestvica predstavlja simetriju kategorija oko sredine s jasno definiranim jezičnim kvalifikacijama. U takvu simetričnom skaliranju bit će jasnije promatrani atributi na jednakom odstojanju, tj. kad je Likertova ljestvica simetrična i jednako udaljena, ponašat će se više kao mjerna ljestvica na razini intervala. Stoga, iako Likertova ljestvica jest ordinalna ljestvica, ako je dobro predstavljena može približiti mjerenje na razini intervala. S obzirom na navedeno i s obzirom na to da istraživači često primjenjuju ovo pravilo, u ovom će se istraživanju podatci analizirati kao da su prikupljeni na intervalnoj ljestvici.

Analizom pouzdanosti (reliability analysis) utvrdit će se stabilnost i dosljednost mjernog instrumenta, tj. ispitat će se pouzdanost izlučenih faktora. U društvenim se znanostima najčešće upotrebljava mjera pouzdanosti Cronbach alpha koeficijent. Ovaj je koeficijent posebno prikladan za utvrđivanje pouzdanosti mjernog instrumenta (upitnika) koji sadržava više tvrdnji (pitanja), a odgovori se ocjenjuju na Likertovoj ljestvici. Analizi pouzdanosti podvrgnuti su čimbenici (dimenzije) koji su bili izlučeni eksploratornom faktorskom analizom. Iako se smatra

da bi vrijednost Cronbach alpha koeficijenta trebala biti iznad 0,70, često se u istraživanjima prihvaćaju i vrijednosti oko 0,60. U ovom radu prihvatljivim će se smatrati koeficijenti čija je vrijednost iznad 0,70, tj. takvi rezultati pokazuju zadovoljavajuću pouzdanost. Faktorska analiza i analiza pouzdanosti izvršit će se na 30 tvrdnji kojima je ocjenjivana suglasnost menadžera s pojedinim tvrdnjama o inovacijskim sposobnostima poduzeća. Nakon provedene analize, pet je tvrdnji iterativnim postupcima eliminirano iz daljnje analize (od inicijalne 34 tvrdnje) zbog niskih vrijednosti komunaliteta. Eliminirane tvrdnje jesu: tehnologija usklađena s poslovnim ciljevima i strategijom, povezivanjem s drugima smanjen rizik i troškovi inovacija, razvijen sustav poboljšanja i unapređenja proizvoda/usluga (npr. benchmarking) te upotreba ključnih naprednih tehnologija; pouzdana isporuka u dogovorenom roku.

Deskriptivna analiza čestica inovacijskih sposobnosti

Svrha deskriptivne statističke analize jest prikupljene podatke opisati i prikazati na razumljiv i pregledan način. U sljedećoj tablici prikazani su rezultati analize inovacijske sposobnosti HR NTP 2015.

Tablica 37: Deskriptivna analiza inovacijskih sposobnosti poduzeća

| Čestice (n = 30) | N | Aritm. sredina | Stand. devijacija | Stand. greška | Mod | Koef. asimet. | Koef. zaobljen. |
|--|----|-------------------|----------------------|------------------|-----|------------------|--------------------|
| inovacijska strategija u korporativnoj strategiji i planovima te razvoj novih ideja | 75 | 4,56 | 1,662 | 0,192 | 5 | -0,570 | -0,626 |
| definiran (mjerni) sustav pokazatelja uspješnosti koji potiče inovacije kroz sustav nagrađivanja | 75 | 3,33 | 1,455 | 0,168 | 2 | 0,232 | -0,840 |
| upravljanje intelektualnim kapitalom | 75 | 4,20 | 1,336 | 0,154 | 5 | -0,622 | -0,322 |
| praćenje, analiza i ocjena rezultata u procesu upravljanja inovacijom | 75 | 4,44 | 1,629 | 0,188 | 5 | -0,747 | 0,628 |
| paralelno upravljanje s više inovacijskih projekata | 75 | 4,99 | 1,457 | 0,168 | 5 | -10,028 | 0,901 |
| prilagodba organizacijske strukture novim inovacijskim projektima | 75 | 4,68 | 1,377 | 0,159 | 5 | -0,738 | 0,116 |

| Čestice (n = 30) | N | Aritm. sredina | Stand. devijacija | Stand. greška | Mod | Koef. asimet. | Koef. zaobljen. |
|---|----|-------------------|----------------------|------------------|-----|------------------|--------------------|
| reakcija i prilagodba zahtjevima vanjskog okruženja | 75 | 4,80 | 1,414 | 0,163 | 5 | -0,695 | 0,223 |
| koordinacija i suradnja između R&D, marketing i proizvodnog odjela | 75 | 4,77 | 1,321 | 0,153 | 5 | -0,905 | 0,535 |
| visok stupanj autonomije nižeg menadžmenta | 75 | 4,17 | 1,589 | 0,183 | 6 | -0,189 | -0,942 |
| veza R&D plana s poslovnim planom poduzeća i tehnološkim kompetencijama | 75 | 4,39 | 1,800 | 0,208 | 6 | -0,860 | 0,550 |
| brza i kvalitetna povratna informacija iz proizvodnog odjela | 75 | 5,04 | 1,528 | 0,176 | 6 | -10,469 | 20,910 |
| komunikacija s marketinškim odjelom | 75 | 4,65 | 1,820 | 0,210 | 6 | -10,415 | 20,144 |
| sustavno praćenje trendova o budućim i tehnologijama u nastajanju (FET) | 75 | 4,03 | 1,816 | 0,210 | 5 | -0,375 | -0,639 |
| razvoj novih tehnoloških rješenja | 75 | 4,08 | 1,901 | 0,220 | 5 | -0,505 | -0,890 |
| zapošljavanje, razvoj, ocjenjivanje i nagrađivanje zaposlenika | 75 | 4,68 | 1,387 | 0,160 | 5 | -0,806 | 0,470 |
| sustavna financijska potpora inovacijskoj aktivnosti | 75 | 4,21 | 1,562 | 0,180 | 6 | -0,955 | 0,562 |
| odgovorni zaposlenici | 75 | 5,21 | 1,407 | 0,163 | 5 | -0,869 | 0,619 |
| kreativni zaposlenici | 75 | 4,91 | 1,454 | 0,168 | 5 | -10,380 | 30,253 |
| poticaj zaposlenicima za razvoj novih ideja | 75 | 4,61 | 1,432 | 0,165 | 5 | -10,184 | 20,760 |
| brza implementacija ideje sve do lansiranja na tržište | 75 | 4,23 | 1,494 | 0,172 | 5 | -0,650 | 10,028 |
| mogućnost brzog preuzimanja inovacije od drugih | 75 | 4,47 | 1,464 | 0,169 | 5 | -0,569 | -0,293 |
| proizvodni proces u skladu sa zahtjevima R&D procesa | 75 | 4,52 | 1,492 | 0,172 | 6 | -10,005 | 10,502 |
| proizvodni odjel uključen u ranoj fazi razvoja novog proizvoda | 75 | 5,19 | 1,495 | 0,173 | 5 | -10,376 | 30,061 |
| visoka tehnološka razina proizvodne opreme | 75 | 4,84 | 1,516 | 0,175 | 4 | -10,777 | 40,677 |
| zaposlenici s visokom operativnom razinom sposobnosti upravljanja proizvodnom opremom | 75 | 4,63 | 1,617 | 0,187 | 6 | -10,357 | 20,709 |
| dugoročni odnosi s kupcima s ciljem razumijevanja njihovih različitih zahtjeva | 75 | 5,76 | 1,089 | 0,126 | 5 | -10,828 | 50,585 |

| Čestice (n = 30) | N | Aritm. sredina | Stand. devijacija | Stand. greška | Mod | Koef. asimet. | Koef. zaobljen. |
|--|----|-------------------|----------------------|------------------|-----|------------------|--------------------|
| povećanje tržišnog udjela marketinškim aktivnostima | 75 | 4,91 | 1,367 | 0,158 | 6 | -0,935 | 10,283 |
| kvalitetna usluga nakon prodaje | 75 | 5,35 | 1,547 | 0,179 | 5 | -10,799 | 30,919 |
| upravljanje i kontrola distribucijske mreže | 75 | 5,17 | 1,349 | 0,156 | 6 | -10,410 | 10,956 |
| predviđanje promjena u kupčevim preferencijama | 75 | 5,05 | 1,207 | 0,139 | 6 | -10,289 | 20,739 |

Izvor: Istraživanje autora

Inovacijske sposobnosti hrvatskih prerađivačkih poduzeća niske i srednje niske tehnološke razine ispitanici su ocjenjivali Likertovom ljestvicom sa sedam ocjena. Aritmetička sredina, tj. prosječne ocjene 30 varijabli (čestica) kreću se u rasponu od 3,33 do 5,76. Najniža prosječna ocjena (3,33) ukazuje na to da se ispitanici najčešće ne slažu (mod je 2) da njihovo poduzeće ima definiran (mjerni) sustav pokazatelja uspješnosti koji potiče inovacije kroz sustav nagrađivanja. Najviša prosječna ocjena (5,76) ukazuje na to da HR NTP njeguje dugoročne odnose s kupcima s ciljem razumijevanja njihovih različitih zahtjeva. Standardne devijacije kreću se unutar intervala (1,089 do 1,901) koji upućuje na malo veću raspršenost podataka od aritmetičke sredine. Skoro su sve vrijednosti koeficijenta asimetrije distribucije negativne, a raspon se kreće od -10,799 do 0,232, što upućuje na to da je većina odgovora ispitanika grupirana u zoni viših vrijednosti, a manja u zoni ekstremno niskih vrijednosti. Koeficijenti zaobljenosti kreću se u rasponu od -0,840 do 50,585 te ukazuju na odstupanje od normalne distribucije (koeficijent zaobljenosti normalne distribucije jest 3).

Prikladnost podataka za provođenje faktorske analize procijenjena je računskim testovima, Kaiser-Mayer-Olkinovom mjerom adekvatnosti uzorka i Bartlettovim testom sferičnosti. Kaiser-Mayer-Olkinova mjera adekvatnosti uzorka (measure of sampling adequacy) jedan je od načina kvantifikacije stupnja korelacije između varijabli i opravdanosti faktorske analize. Indeks se kreće u granicama od 0 do 1. Što je mjera adekvatnosti uzorka bliža jedinici, to je lakše predvidjeti određenu varijablu s pomoću ostalih varijabli. KMO mjera adekvatnosti uzorka promatra se prema sljedećoj ljestvici: preko 0,80 vrlo jaka korelacija; između 0,70 i 0,80 jaka; između 0,60 i 0,70 srednja; između 0,50 i 0,60 slaba te ispod 0,50 neprihvatljiva korelacija.

Bartlettov test sferičnosti još je jedan način analiziranja korelacijske matrice. Ovaj test analizira postojanje statističke značajnosti, tj. postoji li korelacija između nekih varijabli.

Tablica 38: KMO mjera adekvatnosti uzorka i Bartlettov test sferičnosti

| <i>KMO i Bartlett test</i> | | |
|--|--------------------|----------|
| Kaiser-Meyer-Olkinova mjera adekvatnosti uzorka. | | |
| 0,855 | | |
| Bartlettov test sferičnosti | hi-kvadrat | 1864.513 |
| | Stup. Slobode (df) | 435 |
| | Signifikantnost | 0,000 |

Izvor: Istraživanje autora

Kao što je vidljivo u tablici 38, Kaiser-Mayer-Olkinova mjera adekvatnosti uzorka (KMO) vrlo je visoka i iznosi 0,855, što upućuje na to da izlučeni faktori sadržavaju dovoljno varijabli. Ova mjera varira između 0 i 1, a bolje su vrijednosti bliže 1 (vrijednost 0,6 predloženi je minimum). Bartlettov test statistički je značajan ($\chi^2 = 1864,513$; $df = 435$; $p < 0,01$), što ukazuje na jaku korelaciju između faktora i varijabli. Iako je broj ispitanih poduzeća tek 2,5 puta viši (75/30) od broja čestica (varijabli, tvrdnji), navedene vrijednosti upućuju na to da su podaci o inovacijskim sposobnostima poduzeća za cjelokupni uzorak prikladni za provedbu eksploratorne faktorske analize.

Iako u literaturi ne postoji konačan dogovor o najmanjoj veličini uzorka potrebnoj za provođenje faktorske analize, slijedi li se istraživanje koje su o odnosu ispitanika i čestica u eksploratornoj faktorskoj analizi proveli Costello i Osborne (2005) (tablica 39), vidljivo je da je čak 40,5 % sličnih istraživanja u analizi upotrijebilo omjer veći od 2 : 1, a manji od 5 : 1.

Tablica 39: **Odnos ispitanika i čestica u faktorskoj analizi**

| Odnos ispitanika i čestica | % studija | Kumulativ % |
|-------------------------------|-----------|-------------|
| 2 : 1 i manje | 14,7 % | 14,7 % |
| > 2 : 1, ≤ 5 : 1 | 25,8 % | 40,5 % |
| > 5 : 1, ≤ 10 : 1 | 22,7 % | 63,2 % |
| > 10 : 1, ≤ 50 : 1 | 15,4 % | 78,6 % |
| > 50 : 1, ≤ 100 : 1 | 18,4 % | 97,0 % |
| > 100 : 1 | 3,0 % | 100,0 % |

Izvor: Autor prema Costello i Osborne, 2005.

U većini studija u istraživanju Costello i Osborne (2005) njih 63,2 %, istraživači su proveli analize s predmetom omjera stavki od 10 : 1 ili manje, što je staro i još uvijek prevladavajuće pravilo, a mnogi se istraživači njime koriste za određivanje *a priori* veličine uzorka. Iznenadujuće visok udio od 14,7 % (gotovo jedna šestina) istraženih faktorskih analiza temelji se na omjeru ispitanika i čestica od samo 2 : 1 ili manje. Stroga pravila o veličini uzorka za eksploratornu faktorsku analizu uglavnom ne postoje. Istraživanja su pokazala da odgovarajuću veličinu uzorka djelomično određuje i priroda podataka (Fabrigar et al., 1999; MacCallum, et al., 1999). Općenito, što su podaci „jači”, to manji uzorak može biti potreban za točnu analizu. „Jaki” podatci u faktorskoj analizi podrazumijevaju ravnomjerno visoke komunalitete bez križanja uz dodatak nekoliko snažnih faktorskih opterećenja čestica (varijabli) na svaki faktor (Costello i Osborne, 2005).

Kako bi se veći broj neovisnih varijabli prikazao manjim brojem faktora, upotrijebljena je eksploratorna faktorska analiza s metodom ekstrakcije *Principal Axis Factoring* (PAF). Tablica 40 prikazuje inicijalne svojstvene vrijednosti – *eigenvalues* po faktorima i objašnjenje varijance za pojedine faktore u odnosu na ukupnu varijancu.

Tablica 40: Izlučeni faktori i varijanca

| Faktor | Inicijalna svojstvena vrijednost – <i>Eigenvalue</i> | | | Izlučivanje opterećenja faktora iz sume kvadrata | | |
|--------|---|-------------|-------------|--|-------------|-------------|
| | Ukupno | Varijanca % | Kumulativ % | Ukupno | Varijanca % | Kumulativ % |
| 1 | 13,573 | 45,242 | 45,242 | 13,248 | 44,159 | 44,159 |
| 2 | 2,587 | 8,622 | 53,865 | 2,308 | 7,694 | 51,854 |
| 3 | 1,705 | 5,685 | 59,550 | 1,361 | 4,535 | 56,389 |
| 4 | 1,534 | 5,114 | 64,664 | 1,162 | 3,874 | 60,263 |
| 5 | 1,350 | 4,501 | 69,165 | 1,011 | 3,372 | 63,635 |
| 6 | 1,176 | 3,919 | 73,084 | ,832 | 2,775 | 66,410 |


Metoda ekstrakcije: Principal Axis Factoring.

Izvor: Istraživanje autora

Eksploratornom faktorskom analizom izlučeno je šest faktora za cjelokupan uzorak (45,24 % varijance pripisano je prvom faktoru, 8,62 % drugom faktoru, 5,68 % i 5,11 % trećem, odnosno četvrtom faktoru itd.). Kumulativno svih šest izdvojenih faktora objašnjava 73,08 % ukupne varijance. Ukupni je postotak varijance visok i pokazuje da izlučeni faktori sadržavaju 73 % informacija svih izvornih varijabli, što ukazuje na dobru međusobnu povezanost varijabli. Svojstvena vrijednost svakog izlučenog faktora veća je od 1. Na temelju tih rezultata vidljivo je da su zadovoljeni kriteriji za utvrđivanje broja izlučenih faktora.

Grafički odnos broja izdvojenih faktora i pripadajućih inicijalnih svojstvenih vrijednosti – *Eigenvalues* – prikazan je na slici 22.

Grafikon 22: Scree test



Izvor: Istraživanje autora

Na Cattelijevu dijagramu ili Scree testu vidljivo je da se linija kojom je prikazan međuodnos inicijalnih svojstvenih vrijednosti i broja izdvojenih faktora iznimno oštro spušta na prijelazu s prvog faktora na drugi faktor i s drugog faktora na treći faktor te se zatim postupno spušta do šestog izdvojenog faktora. Nakon sedmog faktora linija je gotovo ujednačena, bez izrazitih pragova. Međutim, kad se pad prekine, a krivulja postavi „lakat” prema manje strmom padu, Cattellov test (1966) pokazuje da svi daljnji faktori nakon onog kojim započinje “lakat” ispadaju iz promatranja. Slijedeći Cattella te uzimajući u obzir prethodno navedena očitavanja s grafičkog prikaza, optimalan broj faktora koji se može zadržati iznosi šest. Šest odabranih faktora zadovoljava i Keiserov kriterij²⁷, tj. inicijalne svojstvene vrijednosti (*Eigenvalues*) u rasponu su od 1,18 do 13,57. Kumulativno svih šest izdvojenih faktora objašnjava 73,08 % ukupne varijance.

²⁷ Otpuštanje faktora kod kojih je inicijalna svojstvena vrijednost manja od 1

Nakon utvrđivanja broja faktora izrađena je matrica faktorske strukture izlučenih faktora koja sadržava faktorska opterećenja. Uz PAF metodu ekstrakcije, rotacija faktora provodi se metodom Direct Oblimin s Kaiser normalizacijom. U matrici faktorske strukture značajna su faktorska opterećenja (*factor loadings*) s vrijednosti većom ili jednakom $\pm 0,3$, dok faktor tvore najmanje tri čestice (tvrdnje).

Tablica 41: Rezultati faktorske analize

| Čestice (n = 30) | Faktorska opterećenja | | | | | | Komuna- liteti |
|--|-----------------------|---------------|--------------|--------|--------|--------|-------------------|
| | F1 | F2 | F3 | F4 | F5 | F6 | |
| prilagodba organizacijske strukture novim inovacijskim projektima | 0,666 | | 0,146 | | -0,143 | 0,247 | 0,805 |
| paralelno upravljanje s više inovacijskih projekata | 0,553 | -0,188 | 0,190 | 0,140 | | 0,128 | 0,709 |
| reakcija i prilagodba zahtjevima vanjskog okruženja | 0,431 | | | 0,239 | -0,373 | | 0,689 |
| odgovorni zaposlenici | 0,426 | -0,294 | | | -0,392 | | 0,648 |
| poticaj zaposlenicima za razvoj novih ideja | 0,419 | -0,303 | | | -0,228 | | 0,621 |
| upravljanje i kontrola distribucijske mreže | | -0,803 | | | | | 0,644 |
| predviđanje promjena u kupčevim preferencijama | | -0,751 | | 0,103 | -0,117 | | 0,821 |
| dugoročni odnosi s kupcima s ciljem razumijevanja njihovih različitih zahtjeva | | -0,738 | 0,160 | -0,121 | -0,177 | | 0,755 |
| povećanje tržišnog udjela marketinškim aktivnostima | | -0,701 | | | | 0,126 | 0,576 |
| definiran (mjerni) sustav pokazatelja uspješnosti koji potiče inovacije kroz sustav nagrađivanja | | | 0,754 | | | | 0,566 |
| praćenje, analiza i ocjena rezultata u procesu upravljanja inovacijom | -0,232 | | 0,704 | | | 0,212 | 0,659 |
| upravljanje intelektualnim kapitalom | 0,121 | -0,265 | 0,556 | | | | 0,607 |
| sustavna financijska potpora inovacijskoj aktivnosti | 0,296 | -0,244 | 0,548 | 0,166 | 0,181 | | 0,683 |
| zapošljavanje, razvoj, ocjenjivanje i nagrađivanje zaposlenika | 0,408 | -0,309 | 0,465 | | 0,158 | -0,114 | 0,694 |
| inovacijska strategija u korporativnoj strategiji i planovima te razvoj novih ideja | -0,157 | -0,178 | 0,456 | | -0,388 | 0,206 | 0,689 |

| Čestice (n = 30) | Faktorska opterećenja | | | | | | Komunaliteti |
|---|-----------------------|--------|--------------|--------------|---------------|--------------|--------------|
| | F1 | F2 | F3 | F4 | F5 | F6 | |
| visok stupanj autonomije nižeg menadžmenta | 0,219 | 0,137 | 0,400 | 0,246 | -0,150 | | 0,499 |
| produktivni proces u skladu sa zahtjevima R&D procesa | | 0,246 | | 0,717 | -0,153 | 0,430 | 0,939 |
| visoka tehnološka razina proizvodne opreme | | | 0,120 | 0,670 | -0,113 | -0,197 | 0,521 |
| produktivni odjel uključen u ranoj fazi razvoja novog proizvoda | -0,160 | -0,291 | | 0,516 | 0,194 | 0,439 | 0,595 |
| zaposlenici s visokom operativnom razinom sposobnosti upravljanja proizvodnom opremom | 0,321 | -0,299 | -0,110 | 0,456 | | | 0,557 |
| kreativni zaposlenici | | | -0,104 | 0,158 | -0,768 | | 0,735 |
| razvoj novih tehnoloških rješenja | | -0,219 | 0,145 | | -0,456 | 0,209 | 0,609 |
| moćnost brzog preuzimanja inovacije od drugih | 0,367 | | 0,142 | 0,125 | -0,444 | 0,196 | 0,702 |
| sustavno praćenje trendova o budućim i tehnologijama u nastajanju (FET) | | | 0,228 | | -0,436 | 0,310 | 0,692 |
| kvalitetna usluga nakon prodaje | -0,182 | -0,306 | 0,215 | 0,173 | -0,429 | -0,292 | 0,543 |
| brza implementacija ideje sve do lansiranja na tržište | 0,227 | -0,205 | 0,176 | -0,131 | -0,398 | 0,170 | 0,585 |
| komunikacija s marketinškim odjelom | | | | | | 0,784 | 0,696 |
| veza R&D plana s poslovnim planom poduzeća i tehnološkim kompetencijama | | | 0,289 | | -0,225 | 0,590 | 0,666 |
| brza i kvalitetna povratna informacija iz proizvodnog odjela | 0,472 | | | 0,106 | | 0,568 | 0,808 |
| koordinacija i suradnja između R&D, marketing i proizvodnog odjela | 0,129 | | 0,254 | 0,195 | -0,187 | 0,348 | 0,607 |

Metoda ekstrakcije: Principal Axis Factoring.

Metoda rotacije: Oblimin s Kaiser normalizacijom.^a

a. Rotacija konvergirana u 33 iteracije

Izvor: Istraživanje autora

Na temelju faktorske matrice nakon provedene Direkt Oblimin rotacije kao metode kosokute rotacije, utvrđeno je koje čestice (tvrdnje) tvore šest skupina združenih u faktore. Dobivena matrica faktorske strukture pokazuje da svih 30 čestica unutar šest faktora imaju zadovoljavajuću vrijednost komunaliteta. Komunaliteti se kreću u rasponu od 0,499 do 0,939, što upućuje na to da je varijanca izvornih vrijednosti dobro objašnjena s izlučenim faktorima. Pojedine čestice koreliraju s više faktora, a na prikazanoj faktorskoj strukturi nakon rotacije

jasno su označena značajna faktorska opterećenja. Također, sve skupine sadržavaju više od tri čestice te se kao takve mogu smatrati faktorima.

Interpretacija faktora i pridruživanje imena svakom faktoru subjektivnog su karaktera te je jako važno da se najvjernije prikaže važnost faktora u predikciji svake izvorne varijable (čestice). Prvi faktor obuhvaća pet čestica (prilagodba organizacijske strukture novim inovacijskim projektima; paralelno upravljanje s više inovacijskih projekata; reakcija i prilagodba zahtjevima vanjskog okruženja; odgovorni zaposlenici; poticaj zaposlenicima za razvoj novih ideja) te je nazvan **organizacijska sposobnost**. Faktorska opterećenja unutar prvog faktora kreću se u rasponu od 0,419 do 0,666. Faktorska opterećenja predstavljaju koeficijente korelacije između faktora i varijabli (čestica) te ukazuju na važnost svake varijable za pojedini faktor.

Drugi faktor obuhvaća četiri čestice (predviđanje promjena u kupčevim preferencijama; dugoročni odnosi s kupcima s ciljem razumijevanja njihovih različitih zahtjeva; povećanje tržišnog udjela marketinškim aktivnostima; upravljanje i kontrola distribucijske mreže) te je nazvan **marketinška sposobnost**. Faktorska opterećenja prilično su visoka i kreću se u rasponu od -0,701 do -0,803.

Treći faktor obuhvaća sedam čestica (definiran (mjerni) sustav pokazatelja uspješnosti koji potiče inovacije kroz sustav nagrađivanja; praćenje, analiza i ocjena rezultata u procesu upravljanja inovacijom; upravljanje intelektualnim kapitalom; sustavna financijska potpora inovacijskoj aktivnosti; zapošljavanje, razvoj, ocjenjivanje i nagrađivanje zaposlenika; inovacijska strategija u korporativnoj strategiji i planovima te razvoj novih ideja; visok stupanj autonomije nižeg menadžmenta) te je nazvan **sposobnost strateškog upravljanja**. Faktorska opterećenja unutar trećeg faktora kreću se u rasponu od 0,400 do 0,754.

Četvrti faktor obuhvaća četiri čestice (proizvodni proces u skladu sa zahtjevima R&D procesa; visoka tehnološka razina proizvodne opreme; proizvodni odjel uključen u ranoj fazi razvoja novog proizvoda; zaposlenici s visokom operativnom razinom sposobnosti upravljanja proizvodnom opremom) te je nazvan **proizvodna sposobnost**. Faktorska opterećenja kreću se u rasponu od 0,456 do 0,717.

Peti faktor obuhvaća šest čestica (kreativni zaposlenici; razvoj novih tehnoloških rješenja; mogućnost brzog preuzimanja inovacije od drugih; sustavno praćenje trendova o budućim i tehnologijama u nastajanju (FET); kvalitetna usluga nakon prodaje; brza implementacija ideje sve do lansiranja na tržište) te je nazvan *istraživačko-razvojna sposobnost*. Faktorska opterećenja unutar petog faktora kreću se u rasponu od -0,398 do -0,768.

Šesti faktor obuhvaća četiri čestice (komunikacija s marketinškim odjelom; veza R&D plana s poslovnim planom poduzeća i tehnološkim kompetencijama; brza i kvalitetna povratna informacija iz proizvodnog odjela; koordinacija i suradnja između R&D, marketing i proizvodnog odjela) te je nazvan *informacijska i koordinacijska sposobnost*.

Faktorska opterećenja unutar posljednjeg, šestog faktora kreću se u rasponu od 0,348 do 0,784.

Pouzdanosti unutar faktora

Nakon što se utvrde i objasne faktori inovacijskih sposobnosti prerađivačkih poduzeća niske i srednje niske tehnološke razine, treba izmjeriti pouzdanost upitnika kako bi se pokazalo je li upotrijebljeni upitnik primjeren mjerni instrument. Za procjenu pouzdanosti, tj. unutrašnje konzistentnosti, svakog faktora upotrijebljen je Cronbach alpha – α koeficijent. Cronbach α koeficijent ne primjenjuje se za čestice, već je utvrđen za svaki faktor zasebno, a utvrđena je i njegova ukupna vrijednost. Veća vrijednost Cronbach α koeficijenta upućuje na veću pouzdanost, odnosno pokazuje da čestice istog faktora uistinu mjere istu pojavu (Cronbach, 1951; Cronbach, 1990). Koeficijent unutarnje konzistencije temelji se na prosječnoj korelaciji među česticama, pri čemu veličina koeficijenta ovisi o broju čestica i njihovim korelacijama. Pouzdanost će biti veća ako je uzorak ispitanika na kojima se test primjenjuje heterogen. Općeprihvaćeni su standardi da se testovi koji imaju Cronbachov α koeficijent veći od 0,9 smatraju vrlo visokopouzdanim, iznad 0,8 visokopouzdanim, a iznad 0,7 zadovoljavajuće pouzdanim (Bukvić, 1982).

Tablica 42: Prihvatljive vrijednosti Cronbach alpha koeficijenta

| Vrijednost Cronbach alpha koeficijenta | Tumačenje vrijednosti (ocjena prihvatljivosti) |
|--|--|
| > 0,9 | Izvršno |
| 0,8 do 0,9 | Vrlo dobro |
| 0,7 do 0,8 | Dobro |
| 0,6 do 0,7 | Osrednje |
| 0,5 do 0,6 | Slabo |
| < 0,5 | Neprihvatljivo |

Izvor: Autor prema George i Mallery (2003)

U nastavku je određena valjanost pojedinih faktora korigiranom međučestičnom („inter-item”) korelacijom i provjerom međusobnih odnosa aritmetičkih sredina, varijancija i Cronbach α koeficijenta. Prema Cronbachu (1951), diskriminativna valjanost pojedinih faktora provjerena je usporedbom raspona korelacije faktorskih čestica s pripadajućom ljestvicom te raspona korelacije tih istih čestica s ostalim faktorskim ljestvicama.

Tablica 43 prikazuje statistiku među česticama, interkorelaciju („*inter-item*”) te pouzdanost unutar prvog faktora. Koeficijent pouzdanosti Cronbach alpha – α u prvom je faktoru prilično visok te iznosi 0,895. Ako se pojedine čestice izostave iz Faktora 1, raspon aritmetičkih sredina ljestvice varira od 19,08 do 19,68. Ako se pojedina čestica izbací, varijance ljestvice variraju od 22,35 do 24,18. Korigirane korelacije čestica s pripadajućom ljestvicom u rasponu su od 0,669 do 0,803, što podrazumijeva srednje jake do vrlo jake korelacije.

Prema Cronbachu (1951), vrijednosti korelacija između čestica i pripadajuće ljestvice smatraju se zadovoljavajućima ako su veće od 0,400. Ako se pojedina čestica izbacila, Cronbach α koeficijent u rasponu je od 0,859 do 0,888.

Tablica 43: Statistika čestica i pouzdanost unutar faktora *Organizacijska sposobnost*

| Statistika pouzdanosti | | | | |
|---|---|---|---|---|
| Cronbach α | | Broj čestica | | |
| 0,895 | | 5 | | |
| Čestice | Aritmetička sredina ljestvice ako se čestica izbacila | Varijanca ljestvice ako se čestica izbacila | Korigirana korelacija čestica – ljestvica | Cronbach α ako se čestica izbacila |
| prilagodba organizacijske strukture novim inovacijskim projektima | 19,61 | 22,94 | 0,803 | 0,859 |
| paralelno upravljanje s više inovacijskih projekata | 19,31 | 22,35 | 0,795 | 0,860 |
| reakcija i prilagodba zahtjevima vanjskog okruženja | 19,49 | 23,47 | 0,727 | 0,876 |
| odgovorni zaposlenici | 19,08 | 24,18 | 0,669 | 0,888 |
| poticaj zaposlenicima za razvoj novih ideja | 19,68 | 23,38 | 0,721 | 0,877 |

Izvor: Istraživanje autora

Tablica 44 prikazuje statistiku među česticama i pouzdanost unutar drugog faktora. Kako bi se utvrdila pouzdanost ljestvice, izračunat je koeficijent unutarnje konzistencije, Cronbachov α koeficijent koji je prilično visok i iznosi 0,888. Ako se pojedine čestice izbace iz Faktora 2, raspon aritmetičkih sredina ljestvice varira od 15,13 do 15,99. Ako se pojedina čestica izbacila, varijance ljestvice variraju od 10,45 do 12,09. Korigirane korelacije čestica s pripadajućom ljestvicom u rasponu su od 0,704 do 0,821, što podrazumijeva jake do vrlo jake korelacije. Ako se pojedina čestica izbacila, Cronbach α koeficijent u rasponu je od 0,832 do 0,879.

Tablica 44: Statistika čestica i pouzdanost unutar faktora *Marketinška sposobnost*

| Statistika pouzdanosti | | | | |
|--|---|---|---|---|
| Cronbach α | | | Broj čestica | |
| 0,888 | | | 4 | |
| Čestice | Aritmetička sredina ljestvice ako se čestica izbacila | Varijanca ljestvice ako se čestica izbacila | Korigirana korelacija čestica – ljestvica | Cronbach α ako se čestica izbacila |
| predviđanje promjena u kupčevim preferencijama | 15,84 | 10,95 | 0,821 | 0,832 |
| dugoročni odnosi s kupcima s ciljem razumijevanja njihovih različitih zahtjeva | 15,13 | 12,09 | 0,751 | 0,861 |
| povećanje tržišnog udjela marketinškim aktivnostima | 15,99 | 10,77 | 0,704 | 0,879 |
| upravljanje i kontrola distribucijske mreže | 15,72 | 10,45 | 0,767 | 0,852 |

Izvor: Istraživanje autora

Tablica 45 prikazuje statistiku među česticama i pouzdanost unutar trećeg faktora. Koeficijent unutarnje konzistencije, Cronbachov α koeficijent, prilično je visok i iznosi 0,877. Ako se pojedine čestice izbace iz Faktora 3, raspon aritmetičkih sredina ljestvice varira od 24,92 do 26,27. Ako se pojedina čestica izbacila, varijance ljestvice variraju od 47,19 do 50,35. Korigirane korelacije čestica s pripadajućom ljestvicom u rasponu su od 0,577 do 0,701, što podrazumijeva srednje jake do jake korelacije. Ako se pojedina čestica izbacila, Cronbach α koeficijent u rasponu je od 0,853 do 0,870.

Tablica 45: Statistika čestica i pouzdanost unutar faktora *Sposobnost strateškog upravljanja*

| Statistika pouzdanosti | | | | |
|--|---|---|---|---|
| Cronbach α | | Broj čestica | | |
| 0,877 | | 7 | | |
| Čestice | Aritmetička sredina ljestvice ako se čestica izbaci | Varijanca ljestvice ako se čestica izbaci | Korigirana korelacija čestica – ljestvica | Cronbach α ako se čestica izbaci |
| definiran (mjerni) sustav pokazatelja uspješnosti koji potiče inovacije kroz sustav nagrađivanja | 26,27 | 49,20 | 0,678 | 0,856 |
| praćenje, analiza i ocjena rezultata u procesu upravljanja inovacijom | 25,16 | 47,19 | 0,684 | 0,855 |
| upravljanje intelektualnim kapitalom | 25,40 | 50,19 | 0,697 | 0,855 |
| sustavna financijska potpora inovacijskoj aktivnosti | 25,39 | 47,62 | 0,701 | 0,853 |
| zapošljavanje, razvoj, ocjenjivanje i nagrađivanje zaposlenika | 24,92 | 50,35 | 0,655 | 0,860 |
| inovacijska strategija u korporativnoj strategiji i planovima te razvoj novih ideja | 25,04 | 47,77 | 0,637 | 0,862 |
| visok stupanj autonomije nižeg menadžmenta | 25,43 | 49,71 | 0,577 | 0,870 |

Izvor: Istraživanje autora

Tablica 46 prikazuje statistiku među česticama i pouzdanost unutar četvrtog faktora. Kako bi se utvrdila pouzdanost ljestvice, izračunat je koeficijent unutarnje konzistencije, Cronbachov α koeficijent, koji je prilično visok i iznosi 0,854. Ako se pojedine čestice izbace iz Faktora 4, raspon aritmetičkih sredina ljestvice varira od 13,99 do 14,65. Ako se pojedina čestica izbaci, varijance ljestvice variraju od 12,64 do 13,74. Korigirane korelacije čestica s pripadajućom ljestvicom u rasponu su od 0,504 do 0,677, što podrazumijeva srednje do srednje jake korelacije. Ako se pojedina čestica izbaci, Cronbach α koeficijent u rasponu je od 0,651 do 0,746.

Tablica 46: Statistika čestica i pouzdanost unutar faktora *Proizvodna sposobnost*

| Statistika pouzdanosti | | | | |
|---|---|---|---|---|
| Cronbach α | | | Broj čestica | |
| 0,854 | | | 4 | |
| Čestice | Aritmetička sredina ljestvice ako se čestica izbací | Varijanca ljestvice ako se čestica izbací | Korigirana korelacija čestica – ljestvica | Cronbach α ako se čestica izbací |
| proizvodni proces u skladu sa zahtjevima R&D procesa | 14,65 | 12,64 | 0,677 | 0,651 |
| visoka tehnološka razina proizvodne opreme | 14,33 | 13,63 | 0,546 | 0,721 |
| proizvodni odjel uključen u ranoj fazi razvoja novog proizvoda | 13,99 | 13,74 | 0,547 | 0,721 |
| zaposlenici s visokom operativnom razinom sposobnosti upravljanja proizvodnom opremom | 14,55 | 13,44 | 0,504 | 0,746 |

Izvor: Istraživanje autora

Tablica 47 prikazuje statistiku među česticama i pouzdanost unutar petog faktora. Kako bi se utvrdila pouzdanost ljestvice, izračunat je koeficijent unutarnje konzistencije, Cronbachov α koeficijent, koji je, kao i kod prijašnjih faktora, prilično visok i iznosi 0,871. Ako se pojedine čestice izostave iz Faktora 5, raspon aritmetičkih sredina ljestvice varira od 21,71 do 23,03. Ako se pojedina čestica izbací, varijance ljestvice variraju od 36,86 do 45,32. Korigirane korelacije čestica s pripadajućom ljestvicom u rasponu su od 0,475 do 0,765, što podrazumijeva slabu do jaku korelaciju. Ako se pojedina čestica izbací, Cronbach α koeficijent u rasponu je od 0,832 do 0,880.

Tablica 47: Statistika čestica i pouzdanost unutar faktora *Istraživačko-razvojna sposobnost*

| Statistika pouzdanosti | | | | |
|---|---|---|---|---|
| Cronbach α | | | Broj čestica | |
| 0,871 | | | 6 | |
| Čestice | Aritmetička sredina ljestvice ako se čestica izbaci | Varijanca ljestvice ako se čestica izbaci | Korigirana korelacija čestica – ljestvica | Cronbach α ako se čestica izbaci |
| kreativni zaposlenici | 22,15 | 42,13 | 0,708 | 0,844 |
| razvoj novih tehnoloških rješenja | 22,97 | 36,86 | 0,741 | 0,837 |
| mogućnost brzog preuzimanja inovacije od drugih | 22,59 | 41,92 | 0,713 | 0,843 |
| sustavno praćenje trendova o budućim i tehnologijama u nastajanju (FET) | 23,03 | 37,32 | 0,765 | 0,832 |
| kvalitetna usluga nakon prodaje | 21,71 | 45,32 | 0,475 | 0,880 |
| brza implementacija ideje sve do lansiranja na tržište | 22,83 | 42,61 | 0,654 | 0,852 |

Izvor: Istraživanje autora

Tablica 48 prikazuje statistiku među česticama i pouzdanost unutar posljednjeg, šestog faktora. Koeficijent unutarnje konzistencije, Cronbachov α koeficijent, također je prilično visok i iznosi 0,854.

Ako se pojedine čestice izostave iz Faktora 6, raspon aritmetičkih sredina ljestvice varira od 13,81 do 14,47. Ako se pojedina čestica izbaci, varijance ljestvice variraju od 15,78 do 20,08. Korigirane korelacije čestica s pripadajućom ljestvicom u rasponu su od 0,654 do 0,733, što podrazumijeva srednje jake do vrlo jake korelacije. Ako se pojedina čestica izbaci, Cronbach α koeficijent u rasponu je od 0,800 do 0,836.

Tablica 48: Statistika čestica i pouzdanost unutar faktora *Informacijska i koordinacijska sposobnost*

| Statistika pouzdanosti | | | | |
|---|---|---|---|---|
| Cronbach α | | | Broj čestica | |
| 0,854 | | | 4 | |
| Čestice | Aritmetička sredina ljestvice ako se čestica izbací | Varijanca ljestvice ako se čestica izbací | Korigirana korelacija čestica – ljestvica | Cronbach α ako se čestica izbací |
| komunikacija s marketinškim odjelom | 14,20 | 15,78 | 0,724 | 0,804 |
| veza R&D plana s poslovnim planom poduzeća i tehnološkim kompetencijama | 14,47 | 16,12 | 0,706 | 0,812 |
| brza i kvalitetna povratna informacija iz proizvodnog odjela | 13,81 | 17,78 | 0,733 | 0,800 |
| koordinacija i suradnja između R&D, marketing i proizvodnog odjela | 14,08 | 20,08 | 0,654 | 0,836 |

Izvor: Istraživanje autora

Zaključno, tablica 49 prikazuje međusobnu korelaciju svih faktora iz koje je vidljivo da između šest faktora postoji vrlo slaba korelacija.

Tablica 49: Korelacijska matrica faktora

| Faktor | 1 | 2 | 3 | 4 | 5 | 6 |
|--------|--------|--------|--------|--------|--------|--------|
| 1 | 1,000 | -0,364 | 0,291 | 0,271 | -0,338 | 0,220 |
| 2 | -0,364 | 1,000 | -0,445 | -0,253 | 0,363 | -0,121 |
| 3 | 0,291 | -0,445 | 1,000 | 0,331 | -0,400 | 0,283 |
| 4 | 0,271 | -0,253 | 0,331 | 1,000 | -0,269 | 0,221 |
| 5 | -0,338 | 0,363 | -0,400 | -0,269 | 1,000 | -0,232 |
| 6 | 0,220 | -0,121 | 0,283 | 0,221 | -0,232 | 1,000 |

Metoda ekstrakcije: Principal Axis Factoring.

Metoda rotacije: Oblimin s Kaiser normalizacijom.

Izvor: Istraživanje autora

Empirijsko testiranje inovacijskih sposobnosti među inovacijskim skupinama HR PNT 2015

Nakon što su utvrđeni i objašnjeni faktori inovacijskih sposobnosti hrvatskih prerađivačkih poduzeća niske i srednje niske tehnološke razine te nakon što je procijenjena unutrašnja konzistentnost svih šest faktora, u nastavku će se testirati sljedeća hipoteza:

H9: Ne postoji statistički značajna razlika u procesnim inovacijskim čimbenicima (inovacijskim sposobnostima) inovacijsko vodećih poduzeća u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015

Da bi se ta pretpostavka provjerila, ovisno o distribuciji podataka, primijenit će se parametrijski ili neparametrijski statistički test. Vizualnim pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom ($p < 0,05$ za sve varijable te se može odbaciti hipoteza H_0 u kojoj se navodi da je distribucija podataka normalna) utvrđeno je da podatci za sve tri inovacijske skupine poduzeća HR NTP nisu normalno distribuirani sa z-vrijednostima asimetrije i zaobljenosti izvan intervala $-1,96 - 1,96$, tj. *skewness* (koeficijent asimetrije) od $-1,828$ do $0,232$ (standardna greška (SE) $0,277$) i *kurtosis* (koeficijent zaobljenosti) od $-0,942$ do $5,585$ (SE $0,548$). S obzirom na manji uzorak poduzeća i činjenicu da se distribucija podataka značajno razlikuje od normalne distribucije, upotrijebljeni su Mann-Whitneyjevi neparametrijski testovi. U sljedećoj su tablici prikazani rezultati Mann-Whitneyjeva testa o razlikama u rangovima inovacijskih sposobnosti inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna HR NTP.

Tablica 50: Mann-Whitneyjev test inovacijskih sposobnosti HR NTP 2015

| Čestice | (1 vs 2) ^a | | | | (0 vs 2) | | | |
|--|-----------------------|------------|--------|------------------------|----------------|------------|--------|------------------------|
| | Mann-Whitney U | Wilcoxon W | Z | Asymp. Sig. (2-tailed) | Mann-Whitney U | Wilcoxon W | Z | Asymp. Sig. (2-tailed) |
| Organizacijska sposobnost | | | | | | | | |
| prilagodba organizacijske strukture novim inovacijskim projektima | 312,500 | 978,500 | -1,646 | 0,100 | 60,000 | 196,000 | -3,689 | 0,000*** |
| paralelno upravljanje s više inovacijskih projekata | 287,000 | 953,000 | -2,080 | 0,038** | 51,500 | 187,500 | -3,894 | 0,000*** |
| reakcija i prilagodba zahtjevima vanjskog okruženja | 291,500 | 957,500 | -1,981 | 0,048** | 49,000 | 185,000 | -3,952 | 0,000*** |
| odgovorni zaposlenici | 387,000 | 1053,000 | -0,437 | 0,662 | 78,000 | 214,000 | -3,105 | 0,002*** |
| poticaj zaposlenicima za razvoj novih ideja | 262,000 | 928,000 | -2,464 | 0,014** | 34,000 | 170,000 | -4,446 | 0,000*** |
| Marketinška sposobnost | | | | | | | | |
| upravljanje i kontrola distribucijske mreže | 368,000 | 1034,000 | -0,766 | 0,444 | 85,500 | 221,500 | -3,033 | 0,002*** |
| predviđanje promjena u kupčevim preferencijama | 335,000 | 1001,000 | -1,306 | 0,192 | 75,500 | 211,500 | -3,353 | 0,001*** |
| dugoročni odnosi s kupcima s ciljem razumijevanja njihovih različitih zahtjeva | 291,500 | 957,500 | -2,068 | 0,039** | 82,000 | 218,000 | -3,140 | 0,002*** |
| povećanje tržišnog udjela marketinškim aktivnostima | 248,500 | 914,500 | -2,665 | 0,008*** | 67,000 | 203,000 | -3,428 | 0,001*** |
| Sposobnost strateškog upravljanja | | | | | | | | |
| definiran (mjerni) sustav pokazatelja uspješnosti koji potiče inovacije kroz sustav nagrađivanja | 322,500 | 988,500 | -1,460 | 0,144 | 68,500 | 204,500 | -3,365 | 0,001*** |
| praćenje, analiza i ocjena rezultata u procesu upravljanja inovacijom | 317,000 | 983,000 | -1,578 | 0,115 | 53,000 | 189,000 | -3,795 | 0,000*** |
| upravljanje intelektualnim kapitalom | 357,000 | 1023,000 | -0,956 | 0,339 | 92,500 | 228,500 | -2,750 | 0,006*** |
| sustavna financijska potpora inovacijskoj aktivnosti | 369,500 | 1035,500 | -0,730 | 0,465 | 66,500 | 202,500 | -3,429 | 0,001*** |
| zapošljavanje, razvoj, ocjenjivanje i nagrađivanje zaposlenika | 390,500 | 1056,500 | -0,379 | 0,705 | 90,500 | 226,500 | -2,784 | 0,005*** |
| inovacijska strategija u korporativnoj strategiji i planovima te razvoj novih ideja | 220,000 | 886,000 | -3,147 | 0,002*** | 18,500 | 154,500 | -4,823 | 0,000*** |
| visok stupanj autonomije nižeg menadžmenta | 375,000 | 1041,000 | -0,620 | 0,536 | 86,500 | 222,500 | -2,838 | 0,005*** |
| Proizvodna sposobnost | | | | | | | | |
| proizvodni proces u skladu sa zahtjevima R&D procesa | 347,000 | 1013,000 | -1,116 | 0,265 | 50,500 | 186,500 | -3,979 | 0,000*** |

| Čestice | (1 vs 2) ^a | | | | (0 vs 2) | | | |
|---|-----------------------|------------|--------|------------------------|----------------|------------|--------|------------------------|
| | Mann-Whitney U | Wilcoxon W | Z | Asymp. Sig. (2-tailed) | Mann-Whitney U | Wilcoxon W | Z | Asymp. Sig. (2-tailed) |
| visoka tehnološka razina proizvodne opreme | 410,500 | 1076,500 | -0,057 | 0,955 | 102,000 | 238,000 | -2,423 | 0,015** |
| proizvodni odjel uključen u ranoj fazi razvoja novog proizvoda | 359,500 | 1025,500 | -0,878 | 0,380 | 119,000 | 255,000 | -1,908 | 0,056* |
| zaposlenici s visokom operativnom razinom sposobnosti upravljanja proizvodnom opremom | 400,500 | 1066,500 | -0,217 | 0,828 | 93,000 | 229,000 | -2,749 | 0,006*** |
| Istraživačko-razvojna sposobnost | | | | | | | | |
| kreativni zaposlenici | 381,500 | 1047,500 | -0,534 | 0,593 | 67,000 | 203,000 | -3,418 | 0,001*** |
| razvoj novih tehnoloških rješenja | 262,000 | 928,000 | -2,451 | 0,014** | 27,500 | 163,500 | -4,567 | 0,000*** |
| mogućnost brzog preuzimanja inovacije od drugih | 337,000 | 1003,000 | -1,246 | 0,213 | 65,500 | 201,500 | -3,480 | 0,001*** |
| sustavno praćenje trendova o budućim i tehnologijama u nastajanju (FET) | 244,000 | 910,000 | -2,701 | 0,007*** | 25,000 | 161,000 | -4,617 | 0,000*** |
| kvalitetna usluga nakon prodaje | 326,500 | 992,500 | -1,425 | 0,154 | 102,500 | 238,500 | -2,480 | 0,013*** |
| brza implementacija ideje sve do lansiranja na tržište | 310,500 | 976,500 | -1,663 | 0,096 | 51,000 | 187,000 | -3,910 | 0,000*** |
| Informacijska i koordinacijska sposobnost | | | | | | | | |
| komunikacija s marketinškim odjelom | 255,500 | 921,500 | -2,551 | 0,011** | 54,500 | 190,500 | -3,813 | 0,000*** |
| veza R&D plana s poslovnim planom poduzeća i tehnološkim kompetencijama | 245,000 | 911,000 | -2,709 | 0,007*** | 26,000 | 162,000 | -4,583 | 0,000*** |
| brza i kvalitetna povratna informacija iz proizvodnog odjela | 279,000 | 945,000 | -2,246 | 0,025** | 39,500 | 175,500 | -4,337 | 0,000*** |
| koordinacija i suradnja između R&D, marketing i proizvodnog odjela | 271,000 | 937,000 | -2,371 | 0,018** | 38,000 | 174,000 | -4,293 | 0,000*** |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

*** Signifikantnost na razini pouzdanosti od 99 %, ** Razina pouzdanosti 95 %, * Razina pouzdanosti 90 %

Izvor: Istraživanje autora

Rezultati neparametrijskog testa utvrdili su statistički značajne razlike u rangovima procesnih inovacijskih čimbenika među skupinama HR NTP 2015. Kao što je vidljivo iz tablice 50, između inovacijsko vodećih i neinovativnih poduzeća postoji statistički značajna razlika u svih šest inovacijskih sposobnosti poduzeća. Između ove dvije skupine HR NTP 2015 navedeni je test statistički značajan na razini od 1% za sve tvrdnje unutar sljedećih inovacijskih sposobnosti: organizacijske sposobnosti, marketinške sposobnosti, sposobnosti strateškog upravljanja,

istraživačko-razvojne sposobnosti te informacijske i koordinacijske sposobnosti. Jedino je kod uključenosti proizvodnog odjela u ranoj fazi razvoja novog proizvoda, unutar proizvodne sposobnosti, test statistički značajan na razini od 10 % (p vrijednost = 0,056) te se ta tvrdnja mora tumačiti s odmakom u mišljenju. Zanimljiva je usporedba skupina inovacijsko vodećih poduzeća i inovacijskih sljedbenika jer su skupine poduzeća bile inovacijski aktivne u promatranom razdoblju. Između ovih dviju skupina HR NTP 2015 Mann-Whitneyjev test statistički je značajan test na razini od 1 % i 5 % za sve tvrdnje iz informacijske i koordinacijske sposobnosti (p vrijednost od 0,007 do 0,025). Statistički značajne razlike postoje i unutar organizacijske sposobnosti. Zaključak je da inovacijsko vodeća poduzeća imaju više mogućnosti za paralelno upravljanje s više inovacijskih projekata, brže reagiraju i prilagođavaju se zahtjevima vanjskog okruženja te imaju razvijeniji sustav poticaja zaposlenicima za razvoj novih ideja. Inovacijsko vodeća poduzeća značajno se razlikuju i po efikasnosti marketinških aktivnosti jer potenciraju dugoročne odnose s kupcima s ciljem razumijevanja njihovih različitih zahtjeva. Nadalje, postoji značajna razlika u implementiranju inovacijske strategije u korporativnu strategiju i planove te u razvoju novih ideja između inovacijsko vodećih i inovacijskih sljedbenika HR NTP 2015. Također, unutar istraživačko-razvojnih sposobnosti inovacijsko vodeća poduzeća značajnije razvijaju nova tehnološka rješenja od svojih konkurenata, ali, jednako tako, i istražuju i prate mogućnosti sinergijske aktivnosti u okviru posebnog cilja „buduće tehnologije i tehnologije u nastajanju (FET)”. Zaključno, na temelju rezultata neparametrijskih testova može se zaključiti da postoji statistički značajna razlika u procesnim čimbenicima inovacijsko vodećih i neinovativnih HR NTP 2015, dok je između skupina poduzeća inovacijsko vodećih i inovacijskih sljedbenika ta značajna razlika vidljiva u pojedinim čimbenicima unutar svih šest sposobnosti. U skladu s navedenim, odbacuje se hipoteza *H9* i zaključuje se da postoji statistički značajna razlika u procesnim inovacijskim čimbenicima (inovacijskim sposobnostima) inovacijsko vodećih poduzeća u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015.

4.5.3. Izlazni inovacijski čimbenici HR NTP 2015

Mjerenje izlaznih inovacijskih pokazatelja za inovacije proizvoda (vidjeti poglavlje 4.2.) prednost je inovacijskih upitnika CIS i MIP. Uz udio prihoda generiranog od novih ili značajno poboljšanih proizvoda u trogodišnjem razdoblju, drugi pokazatelj koji se često upotrebljava u empirijskim istraživanjima jest udio prihoda od inovacija proizvoda koji su novi na tržištu. Oba pokazatelja za mjerenje inovacijskih rezultata upotrijebljena su u ovom istraživanju za podjelu poduzeća na inovacijske skupine. Jedna od dodanih vrijednosti MIP upitnika u odnosu na CIS upitnik jest upotreba pokazatelja uspješnosti procesnih inovacija. Cilj je testiranjem statistički značajnih razlika u prosječnim uštedama troškova te poboljšanja u kvaliteti potaknutih inovacijom procesa na primjeru DE NTP testirati hipoteze istom metodologijom i na uzorku HR PNT 2015. Nadalje, polazeći od Schumpeterove klasifikacije i klasifikacije navedene u Priručniku iz Osla (Oslo Manual), izlaznim inovacijskim pokazateljima tehnoloških inovacija (proizvoda i procesa) dodani su i pokazatelji organizacijskih i marketinških inovacija. Uzme li se u obzir činjenica da organizacijske i marketinške inovacije u suštini nemaju tehnoloških elemenata te se ne moraju temeljiti na formalnim R&D aktivnostima kao i da promatrana poduzeća pripadaju skupini nisko tehnološko intenzivnih u domeni istraživanja i razvoja, cilj je u nastavku analizirati inovacijsku aktivnost HR NTP 2015 i izvan područja tehnoloških inovacija. Također, budući da su poduzeća na inovacijske skupine podijeljena na temelju dvaju tehnoloških pokazatelja, tj. inovacija proizvoda, zanimljivo je ispitati razlikuju li se inovacijsko vodeća poduzeća značajno od konkurenata i u drugim vrstama inovacija.


Inovacije procesa

Inovacija procesa jest primjena novoga ili znatno poboljšanoga proizvodnog postupka, načina distribucije proizvoda ili potporne aktivnosti za proizvode i usluge. Inovacija procesa mora biti nova za poduzeće, ali ne nužno za tržište na kojem poduzeće posluje te pritom nije važno je li poduzeće samo razvilo inovaciju ili ju je razvilo neko drugo poduzeće ili institucija.

H10: Inovacijom procesa HR NTP 2015 prosječno štede, povećavaju kvalitetu i pozitivno utječu na razinu inovacija proizvoda

U skladu s CIS metodologijom, na grafikonu 23 prikazana je distribucija odgovora ispitanika na pitanja o implementaciji novih ili znatno poboljšanih metoda proizvodnje proizvoda ili usluga, novih ili znatno poboljšanih logistika, metoda isporuke ili distribucije sirovina, proizvoda ili usluga te novih ili znatno poboljšanih potpornih aktivnosti za poslovne procese poduzeća (npr. sustavi održavanja, nabava, računovodstvo ili računalni sustavi).

Grafikon 23: Inovacije procesa HR NTP 2015



Napomena: Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

Na ordinati (y-osi) prikazan je broj poduzeća.

Izvor: Istraživanje autora


Na pitanje „Je li vaše poduzeće u razdoblju 2013. – 2015. uvelo nove ili znatno poboljšane metode proizvodnje proizvoda ili usluga?“ čak 87 % inovacijsko vodećih prerađivačkih poduzeća odgovorilo je pozitivno (20/23). U skupini inovacijskih sljedbenika potvrdno je odgovorilo 29 poduzeća (od njih 36), odnosno visokih 80,6 %. U skupini neinovativnih samo su dva poduzeća uvela nove ili znatno poboljšane metode proizvodnje proizvoda ili usluga. Novu ili znatno poboljšanu logistiku, metode isporuke ili distribucije sirovina, proizvoda ili usluga u trogodišnjem razdoblju uvelo je 56,5 % inovacijsko vodećih poduzeća (13/23), 38,9 %

inovacijskih sljedbenika (14/36) i nijedno neinovativno poduzeće. Nove ili znatno poboljšane potporne aktivnosti za poslovne procese uvelo je 73,9 % inovacijsko vodećih poduzeća, 69,4 % inovacijskih sljedbenika i 18,8 % neinovativnih HR NTP 2015. Iz prethodne analize vidljivo je da inovacijsko vodeća poduzeća značajnije uvode inovacije procesa u odnosu na inovacijske sljedbenike i neinovativna poduzeća. S obzirom na to da je udio prihoda generiranog od novih ili značajno poboljšanih proizvoda (i usluga) bio temelj za podjelu poduzeća na inovacijske skupine, može se zaključiti da inovacijom procesa HR NTP 2015 pozitivno utječu na razinu inovacija proizvoda.

Fagerberg *et al.* (2004) istaknuli su da se za inovacije proizvoda najčešće pretpostavlja da imaju jasan, pozitivan učinak na rast prihoda i zapošljavanje. No, kad je riječ o procesnim inovacijama, učinak ponekad može biti nejasan zbog njihove prirode koja rezultira smanjenjem troškova. Radi naglašavanja učinka inovacija procesa, u inoviranom upitniku u trećoj fazi istraživanja upotrijebljeni su pokazatelji uspješnosti inovacija procesa preuzeti iz upitnika MIP (2011). Nakon pitanja o uvođenju inovacija procesa poduzeća su izravno upitana jesu li te inovacije procesa dovele do smanjenja jediničnog troška u proizvodnji. Nakon potvrdnog odgovora slijedilo je pitanje o procjeni²⁸ prosječne uštede troškova potaknute inovacijama procesa u referentnim godinama (grafikon 24).

²⁸ Procjena je mjerena skalom od 0 do 8 (intervali vrijednosti u % jesu 0 = 0, 1 = < 5, 2 = < 10, 3 = < 15, 4 = < 20, 5 = < 30, 6 = < 50, 7 = < 75 i 8 = ≤ 100)

Grafikon 24: Prosječne uštede troškova potaknute inovacijama procesa



Napomena: Rezultate treba uzeti s rezervom s obzirom na intervalne vrijednosti; grafikon prikazuje agregirane, prosječne vrijednosti.

Na ordinati (y-osi) prikazane su postotne uštede troškova.

Izvor: Istraživanje autora

Iz grafikona 24 vidljivo je da su najveće postotne prosječne uštede troškova potaknute inovacijama procesa u razdoblju 2013. – 2015. godine prijavila inovacijsko vodeća NTP (19,55 %) poduzeća. Prosječna ušteda troškova u skupini inovacijskih sljedbenika iznosila je 13,79 %, dok su neinovativna NTP ostvarila uštede od 9,17 %. Da bi se testirala statistički značajna razlika u prosječnim uštedama troškova inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015, postavljena je hipoteza:

H10a: Ne postoji statistički značajna razlika u prosječnim uštedama troškova inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015

Vizualnim pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom ($p < 0,05$ za sve varijable te se može odbaciti hipoteza H_0 koja navodi da je distribucija podataka normalna) pokazalo se da podatci za sve tri inovacijske skupine poduzeća HR NTP 2015 nisu normalno distribuirani sa z-vrijednostima asimetrije i zaobljenosti izvan intervala $-1,96 - 1,96$,

tj. *skewness* (koeficijent asimetrije) od -1,828 do 0,232 (standardna greška (SE) 0,277) i *kurtosis* (koeficijent zaobljenosti) od -0,942 do 5,585 (SE 0,548). S obzirom na to da se distribucija podataka značajno razlikuje od normalne distribucije, upotrijebljeni su Mann-Whitneyjevi neparametrijski testovi za utvrđivanje razlike u rangovima pojedinih skupina poduzeća. Tablica 51 prikazuje rezultate Mann-Whitneyjeva testa o prosječnim uštedama troškova inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna HR NTP.

Tablica 51: Mann-Whitneyjev test o prosječnim uštedama troškova HR NTP 2015

| | Prosječna ušteda troškova | |
|------------------------|---------------------------|----------|
| | (0 vs 2) ^a | (1 vs 2) |
| Mann-Whitney U | 35,500 | 295,000 |
| Wilcoxon W | 171,500 | 961,000 |
| Z | -4,342 | -1,910 |
| Asymp. Sig. (2-tailed) | 0,000 *** | 0,056* |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

*** Signifikantnost na razini pouzdanosti od 99 %, * Razina pouzdanosti 90 %


Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva testa potvrđuju postojanje razlike u prosječnoj uštedi troškova zbog inovacija procesa HR NTP 2015. Navedeni je test statistički značajan na razini od 1 % kod inovacijsko vodećih poduzeća i skupine neinovativnih poduzeća (p vrijednost = 0,000), dok je kod usporedbe inovacijsko vodećih poduzeća i inovacijskih sljedbenika test statistički značajan na razini od 10 % (p vrijednost = 0,056). S obzirom na navedeno, može se odbaciti pomoćna hipoteza *H10a* i zaključiti da postoji statistički značajna razlika u prosječnoj uštedi troškova zbog inovacija procesa između inovacijsko vodećih, inovacijskih sljedbenika i neinovativnih hrvatskih prerađivačkih poduzeća niske tehnološke razine.

U domeni pokazatelja uspješnosti inovacija procesa, uz pitanja o prosječnim uštedama na troškovima, MIP upitnik obuhvaća i pitanja o poboljšanjima u kvaliteti potaknutim inovacijama procesa. Nakon filter-pitanja o poboljšanjima u kvaliteti (da/ne), poduzeća su pitana da mjernom

skalom od nula do osam²⁹ ocijene koliko se povećao prihod poduzeća kao rezultat poboljšanja u kvaliteti potaknutih inovacijama procesa. Na grafikonu 25 prikazano je agregirano, prosječno i postotno povećanje prihoda koje je rezultat poboljšanja u kvaliteti potaknutih inovacijama procesa za sve tri skupine HR NTP 2015.

Grafikon 25: Povećanje prihoda kao rezultat poboljšanja u kvaliteti



Napomena: Rezultate treba uzeti s rezervom s obzirom na intervalne vrijednosti; grafikon prikazuje agregirane, prosječne vrijednosti.

Na ordinati (y-osi) prikazano je postotno povećanje prihoda.

Izvor: Istraživanje autora

Vidljivo je da su u razdoblju 2013. – 2015. godine najveće povećanje prihoda kao rezultat poboljšanja u kvaliteti potaknutih inovacijama procesa prijavila inovacijsko vodeća poduzeća, i to čak 22,05 %. Povećanje prihoda kao rezultat poboljšanja u kvaliteti kod skupine inovacijskih sljedbenika iznosila je 15,31 %, dok su neinovativna poduzeća ostvarila povećanje prihoda od 14,17 %. S obzirom na to da grafikon 25 prikazuje agregiranu i prosječnu vrijednost, da bi se

²⁹ Povećanje prihoda mjereno je skalom od 0 do 8 (intervali vrijednosti u % jesu 0 = 0, 1 = < 5, 2 = < 10, 3 = < 15, 4 = < 20, 5 = < 30, 6 = < 50, 7 = < 75 i 8 = ≤ 100)

testirala statistički značajna razlika u poboljšanjima u kvaliteti potaknutih inovacijama procesa među trima skupinama HR NTP 2015, postavljena je hipoteza:

H10b: Ne postoji statistički značajna razlika u povećanju prihoda zbog poboljšanja u kvaliteti inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015

Vizualnim pregledom histograma, plotova, box plotova i Shapiro-Wilkovim testom ($p < 0,05$ za sve varijable) pokazalo se da podatci za sve tri inovacijske skupine HR NTP 2015 nisu normalno distribuirani sa z-vrijednostima asimetrije i zaobljenosti izvan intervala $-1,96 - 1,96$ te su korišteni Mann-Whitneyjevi neparametrijski testovi za utvrđivanje razlike u rangovima pojedinih skupina poduzeća. Tablica 52 prikazuje rezultate Mann-Whitneyjeva testa poboljšanja u kvaliteti potaknutih inovacijom procesa inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna HR NTP u 2015. godini.

Tablica 52: Mann-Whitneyjev test o poboljšanjima u kvaliteti HR NTP 2015

| | <i>Poboljšanja u kvaliteti</i> | |
|------------------------|--------------------------------|----------|
| | (0 vs 2) ^a | (1 vs 2) |
| Mann-Whitney U | 39,500 | 249,500 |
| Wilcoxon W | 175,500 | 915,000 |
| Z | -4,202 | -2,638 |
| Asymp. Sig. (2-tailed) | 0,000 *** | 0,008*** |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

*** Signifikantnost na razini pouzdanosti od 99 %.

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjev testa potvrđuju postojanje razlike kod poboljšanja u kvaliteti zbog inovacija procesa HR NTP 2015. Navedeni je test statistički značajan, signifikantnost testa na razini je pouzdanosti od 99 %, tj. pri usporedbi neinovativnih i inovacijsko vodećih poduzeća 0,000, a pri usporedbi inovacijskih sljedbenika i inovacijsko vodećih 0,008. Ovim testom nije dana potpora (odbacuje se) pomoćnoj hipotezi *H10b* te se može zaključiti da postoji statistički

značajna razlika u poboljšanju kvalitete zbog inovacija procesa skupine inovacijsko vodećih poduzeća i skupina inovacijskih sljedbenika i neinovativnih HR NTP 2015.

S obzirom na to da postoji statistički značajna razlika u prosječnoj uštedi troškova zbog inovacija procesa, statistički značajna razlika u povećanju prihoda zbog poboljšanja kvalitete potaknutog inovacijom procesa te značajna razlika u uvođenju inovacije procesa između inovacijsko vodećih i inovacijskih sljedbenika i neinovativnih hrvatskih poduzeća niske tehnološke razine, može se potvrditi hipoteza *H10* i zaključiti da inovacijama procesa HR NTP 2015 prosječno štede, povećavaju prihod i pozitivno utječu na razinu inovacija proizvoda.

Organizacijske inovacije

Organizacijska inovacija jest nova organizacijska metoda u poslovnoj praksi poduzeća, organizaciji radnog mjesta ili odnosima s drugim subjektima kojom se poduzeće prije nije koristilo. Organizacijska inovacija mora biti rezultat strateške odluke uprave poduzeća. Isključuju se slučajevi preuzimanja i spajanja s drugim poduzećem, čak i ako su se dogodili prvi put.


H11: Organizacijskim inovacijama te inovacijom poslovnog modela HR NTP 2015 pozitivno utječu na razinu inovacija proizvoda

Da bi se testirala statistička razlika u uvođenju novih poslovnih praksi u organizacijskim postupcima inovacijsko vodećih poduzeća i inovacijskih sljedbenika u odnosu na neinovativna HR NTP 2015, postavljena je pomoćna hipoteza. Za testiranje pomoćne hipoteze koristit će se deskriptivna statistika, tj. u opisu zastupljenosti jedne kategorije u uzorku koristit će se relativna frekvencija kategorije. Pomoćna hipoteza glasi:

H11a: Postoji statistička razlika u organizacijskim inovacijama inovacijsko vodećih i inovacijskih sljedbenika u odnosu na neinovativna HR NTP 2015

Na grafikonu 26 prikazana je distribucija odgovora ispitanika na pitanja o implementaciji novih poslovnih praksi u organizacijskim postupcima, npr. upravljanje lancem opskrbe, preoblikovanje poslovnih procesa, upravljanje znanjem, upravljanje kvalitetom itd., novih metoda organizacije radnih dužnosti i odlučivanja, npr. prva upotreba novog sustava radnih dužnosti zaposlenika, timskog rada, decentralizacije, integracije ili dezintegracije odjela, sustava obrazovanja i usavršavanja itd. Također, ispitanici su upitani jesu li u promatranom razdoblju (prvi put) uveli nove metode organizacije odnosa s drugim poduzećima ili javnim institucijama, npr. alijanse, partnerstva, obavljanje dijela procesa izvan poduzeća (*outsourcing*) ili podugovaranje (*sub-contracting*).

Grafikon 26: Organizacijske inovacije HR NTP 2015



Napomena: Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

Na ordinati (y-osi) prikazan je broj poduzeća.

Izvor: Istraživanje autora


Na pitanje „Je li vaše poduzeće u razdoblju 2013. – 2015. uvelo novu poslovnu praksu u organizacijskim postupcima?“ potvrdno je odgovorilo 73,9 % inovacijsko vodećih poduzeća (17/23) i 66,7 % inovacijskih sljedbenika HR NTP 2015 (24/36). U skupini neinovativnih nijedno poduzeće nije uvelo novu poslovnu praksu u organizacijskim postupcima. Nove metode organizacije radnih dužnosti i odlučivanja u trogodišnjem razdoblju implementiralo je 60,9 % inovacijsko vodećih (14/23), 58,3 % inovacijskih sljedbenika (21/36) i 6,3 % neinovativnih

poduzeća (1/16). Nove metode organizacije odnosa s drugim poduzećima ili javnim institucijama realiziralo je 52,2 % inovacijsko vodećih, 44,4 % inovacijskih sljedbenika i nijedno neinovativno HR NTP 2015. Iz prethodne se analize može zaključiti da inovacijsko vodeća poduzeća i inovacijski sljedbenici u većem postotku uvode organizacijske inovacije u odnosu na neinovativna poduzeća. S obzirom na navedeno, može se potvrditi pomoćna hipoteza *H11a* i zaključiti da postoji statistička razlika u organizacijskim inovacijama inovacijsko vodećih i inovacijskih sljedbenika u odnosu na neinovativna HR NTP 2015.

H11b: Postoji statistička razlika u inoviranju poslovnih modela inovacijsko vodećih i inovacijske sljedbenike u odnosu na neinovativna HR NTP 2015

U današnje vrijeme poduzeća moraju inovirati iskorištavanjem svojih unutarnjih resursa, a inovacije moraju uključivati poslovne modele i njihovu inovaciju, a ne samo tehnologiju i R&D. Distribucija odgovora na pitanje “Jeste li u zadnjih pet godina inovirali svoj poslovni model?” prikazana je na grafikonu 27.

Grafikon 27: Inovacija poslovnih modela HR NTP 2015



Napomena: Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

Na ordinati (y-osi) prikazan je udio poduzeća.

Izvor: Istraživanje autora

Pri proučavanju navedene dihotomne varijable pažnja je usmjerena na zastupljenost pojedine kategorije u uzorku, tj. za testiranje pomoćne hipoteze koristit će se relativna frekvencija kategorije. Na pitanje o inovaciji poslovnih modela u petogodišnjem razdoblju potvrdno je odgovorilo 65,2 % inovacijsko vodećih poduzeća. Također, visok postotak inovacije poslovnih modela potvrdilo je 58,3 % inovacijskih sljedbenika. Kod neinovativnih poduzeća samo je jedno poduzeće inoviralo svoj poslovni model. S obzirom na navedeno, može se potvrditi pomoćna hipoteza *H11b* i zaključiti da postoji statistička razlika u inoviranju poslovnih modela inovacijsko vodećih i inovacijskih sljedbenika u odnosu na neinovativna HR NTP 2015.

Iz prethodnih analiza vidljivo je da inovacijsko vodeća poduzeća u većem postotku uvode organizacijske inovacije te da, jednako tako, inoviraju poslovne modele u odnosu na inovacijske sljedbenike i neinovativna poduzeća. S obzirom na to da je udio prihoda generiranog od novih ili značajno poboljšanih proizvoda bio temelj za podjelu poduzeća na inovacijske skupine, može se potvrditi hipoteza *H11* i zaključiti da organizacijskim inovacijama HR NTP 2015 pozitivno utječu na razinu inovacija proizvoda.

Marketinške inovacije


Marketinška inovacija jest primjena novoga marketinškog koncepta ili strategije koja se znatno razlikuje od postojećih marketinških postupaka u poduzeću i koja nije prije korištena. Isključuju se sezonske, redovite i druge rutinske promjene u marketinškim postupcima. Sljedeće kvalitativne varijable razvrstane u kategorije (grafikon 28) koriste dihotomne podatke. Za testiranje sljedeće hipoteze koristit će se deskriptivna statistika, tj. relativna frekvencija unutar kategorija.

H12: Marketinške inovacije HR NTP 2015 pozitivno utječu na razinu inovacija proizvoda

Na grafikonu 28 prikazana je distribucija odgovora ispitanika na pitanje o uvođenju znatne estetske promjene dizajna ili pakiranja proizvoda ili usluga (isključene su promjene koje mijenjaju funkcionalna svojstva proizvoda ili način njegove upotrebe jer se to smatra

inovacijom proizvoda). Također, ispitanici su odgovarali na pitanja o uvođenju novih medija i tehnika promocije proizvoda (npr. prvo korištenje novim medijem za oglašavanje, novi imidž marke, uvođenje kartica lojalnosti itd.), novih načina plasiranja proizvoda na tržište ili novih kanala prodaje (npr. upotreba franšize ili prava zastupanja, izravna prodaja, ekskluzivna maloprodaja, novi koncepti prezentacije proizvoda itd., sve prvi put) te prvog uvođenja novih načina određivanja cijene proizvoda ili usluge (npr. upotreba cijena koje variraju ovisno o potražnji, sustava popusta itd.).

Grafikon 28: Marketinške inovacije HR NTP 2015



Napomena: Grupirajuća varijabla: inovacijska skupina poduzeća (neinovativni = 0, inovacijski sljedbenici = 1 i inovacijsko vodeći = 2)

Na ordinati (y-osi) prikazan je broj poduzeća.

Izvor: Istraživanje autora

Na pitanje „Je li vaše poduzeće u razdoblju 2013. – 2015. uvelo znatne estetske promjene dizajna ili pakiranja proizvoda ili usluga?” potvrdno je odgovorilo 65,2 % inovacijsko vodećih (15/23) i 47,2 % inovacijskih sljedbenika HR NTP 2015 (17/36). Nove medije i tehnike promocije proizvoda uvelo je 47,8 % inovacijsko vodećih poduzeća (11/23), 44,4 % inovacijskih sljedbenika (16/36) i nijedno neinovativno poduzeće (0/16). U trogodišnjem


razdoblju nove načine plasiranja proizvoda na tržište ili nove kanale prodaje implementiralo je 43,5 % inovacijsko vodećih (10/23), 25 % inovacijskih sljedbenika (9/36) i jedno neinovativno poduzeće. Nove načine određivanja cijene proizvoda ili usluga primijenilo je 60,9 % inovacijsko vodećih poduzeća (14/23), 30,6 % inovacijskih sljedbenika (11/36) i nijedno neinovativno HR NTP 2015. Analizom se može zaključiti da inovacijsko vodeća poduzeća u većem postotku uvode marketinške inovacije u odnosu na inovacijske sljedbenike i neinovativna poduzeća.

S obzirom na podjelu poduzeća na inovacijske skupine, može se potvrditi hipoteza *H12* i zaključiti da marketinškim inovacijama HR NTP 2015 pozitivno utječu na razinu inovacija proizvoda.

Inovacijske prepreke i pokazatelji uspješnosti inovacije

U skladu s istraživanjem koje su proveli Andrew *et al.* (2010) iz grupacije Boston Consulting Group, inovirani upitnik sadržava i pitanje povezano s ograničenjima u inovacijskoj aktivnosti. Najveće prepreke s kojima se poduzeća susreću pri inoviranju rangirane su na grafikonu 29.

Grafikon 29: Inovacijske prepreke



Napomena: Poduzeća nisu podijeljena unutar skupina, već su promatrana agregirano.

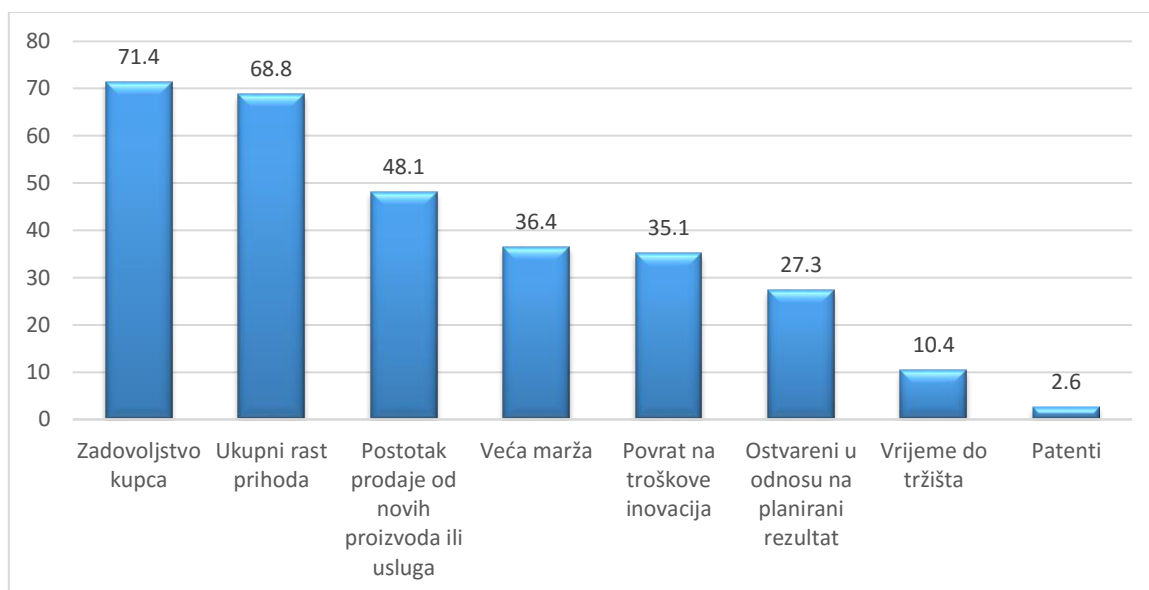
Na ordinati (y-osi) prikazan je udio poduzeća.

Izvor: Istraživanje autora

Na pitanje „Koje su najveće prepreke s kojima se susrećete pri inoviranju?” najučestaliji odgovor (51,9 % anketiranih poduzeća) bio je (pre)dugo vrijeme razvoja. To je u skladu s rezultatima istraživanja *Senior Executive Innovation Survey* grupacije Boston Consulting Group (Andrew *et al.*, 2010) koje dugo vrijeme razvoja također rangira na visoko drugo mjesto. Redom slijede: nedostatak odgovarajućeg financiranja (41,6 %), nemogućnost pravilnog mjerenja rezultata (37,7 %), nedostatak kvalificiranih kadrova (36,4 %), problem sa selektiranjem pravih ideja za komercijalizaciju (32,5 %) i sustav nagrađivanja koji nije povezan s inovacijskim rezultatima (28,6 %). Ostale prepreke jesu: nedostatak pravih ideja (23,4 %), manjak koordinacije u poduzeću (22,1 %), strah od neuspjeha (18,2 %), manjak komunikacije (16,9 %), neefikasan marketing (14,3 %), nedovoljno saznanja o kupčevim preferencijama (7,8 %) te nedovoljno podrške vlasnika i Uprave (6,5 %). Zanimljivo je da je na hrvatskom uzorku strah od neuspjeha prema frekvenciji odgovora rangiran kao manja prepreka, što je u suprotnosti s istraživanjem BCG-a gdje se godinama nalazi na prvim mjestima.

Pravilno definiran mjerni sustav pokazatelja uspješnosti inovacija zasigurno je potreban svakom poduzeću. Međutim, mjere li poduzeća inovacijsku aktivnost na pravilan način? Prema istraživanju koje su proveli Andrew *et al.* (2010), čak 41 % ispitanika nezadovoljno je s mjernim sustavom u vlastitom poduzeću. Također, u prijašnjem odlomku vidi se da je 28,6 % hrvatskih poduzetnika kao prepreku inoviranju naglasilo sustav nagrađivanja koji nije povezan s inovacijskim rezultatima. Na sljedećem grafikonu može se vidjeti distribucija odgovora na pitanje o načinu mjerenja uspjeha inovacija unutar HR NTP.

Grafikon 30: Mjerenje uspješnosti inovacije



Napomena: Poduzeća nisu podijeljena unutar skupina, već su promatrana agregirano.

Na ordinati (y-osi) prikazan je udio poduzeća.

Izvor: Istraživanje autora

Na pitanje „Kako vaše poduzeće mjeri uspjeh inovacije?” 71,4 % anketiranih poduzeća na prvo mjesto stavilo je zadovoljstvo svojih kupaca. Drugi mjerni pokazatelj po frekventnosti je ukupan rast prihoda (68,8 %). Postotak prodaje od novih proizvoda ili usluga s 48,1 % i veća marža s 36,4 % zatvaraju krug od četiri najfrekventnija mjerna pokazatelja uspješnosti inovacije. Zanimljivo, frekvencija odgovora HR NTP 2015 prati rezultate istraživanja *Senior Executive Innovation Survey* (Andrew et al., 2010) u kojemu su prva četiri mjerna pokazatelja rangirana istim redoslijedom. Nakon prva četiri pokazatelja redom slijede: povrat na troškove inovacija (35,1 %), ostvareni u odnosu na planirani rezultat (27,3 %), vrijeme do tržišta (10,4 %) i patenti (2,6 %).

4.5.4. Financijska efikasnost HR PNT 2015

Cilj poslovanja poduzeća jest ostvarenje što boljih financijskih rezultata. Spajanjem primarnih podataka iz inoviranog upitnika i podataka hrvatske Financijske agencije (FINA) pokušat će se utvrditi postoji li pozitivna veza između inovacijske i financijske efikasnosti. Efikasnost ili

uspješnost jedno je od osnovnih mjerila racionalnog poslovanja i izražava se odnosom na prikladan način izraženih dviju strana poslovnog procesa: učinaka i ulaganja (Popović, Vitezić, 2009, 188). Odnosno, proces uspješnog poslovanja predstavlja najpovoljniji odnos između karakteristika učinaka poslovanja s jedne strane i procesa ostvarivanja učinaka s druge strane (Tintor, 2009, 110). Ovisno o odabranim ulaganjima ili inputima i učincima ili outputima, mogu se razlikovati dva temeljna aspekta poslovne uspješnosti: operativni i financijski. Učinci (prihod, dobit) kao i ulaganja (imovina, kapital) izraženi financijskim kategorijama ukazuju na financijsku efikasnost koja se izražava vrijednosnim jedinicama i često predstavlja osnovni ili jedan od važnijih ciljeva poduzeća. Osim tog cilja, mjerenje financijske uspješnosti služi i kao alat za financijsko upravljanje i osnova je za motiviranje i kontrolu (Otley, 2007). Financijska efikasnost ili uspješnost uobičajeno se razmatra kroz rast pojedinih kategorija, npr. prihoda, dodane vrijednosti, odnosno najčešće se mjeri pokazateljem rentabilnosti ili profitabilnosti poslovanja. Najčešće upotrebljavani pokazatelji profitabilnosti u istraživanju u svrhu mjerenja uspjeha (Carton, Hofer, 2006; Delen *et al.*, 2013) jesu povrat na angažiranu imovinu ili ROA (*return on assets*), povrat na uloženi vlastiti kapital ili ROE (*return on equity*), te profitna marža ili ROS (*profit margin*). Istraživanja koja povezuju inovacije i rezultate poslovanja također u najvećem broju slučajeva upotrebljavaju pokazatelje profitabilnosti te pokazatelje rasta (Durán-Vázquez *et al.*, 2012; Likar *et al.*, 2014; Nybakk, Jenssen, 2012; Oke *et al.*, 2012; Yen, 2013). Primjerice, Ferrari i La Rocca (2010, 115-141) razmatraju širi koncept inovacija u prerađivačkoj industriji (ulaganja u R&D, inovacije u procese, proizvode, marketing i organizaciju) i utjecaj na rezultat poslovanja mjeren ROA-om te dokazuju da različite vrste inovacija mogu utjecati na ROA-u. To je u svakom slučaju korisno saznanje za menadžment u slučaju planiranja inovacijske strategije.

H13: Ne postoji statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih u odnosu na neinovativna HR NTP 2015

Kao i u prvoj fazi istraživanja, tri odabrana financijska pokazatelja za analizu jesu dodana vrijednost po zaposlenom, prihod od prodaje i prihod od prodaje po zaposlenom. Pokazatelji prikazuju prosječnu vrijednost svih poduzeća unutar inovacijskih skupina (tablica 53). U odnosu na prvu fazu istraživanja, novost je duži vremenski niz, tj. dodavanje 2016. godine koja se

smatra iznimno važnom zbog naglašavanja učinka inovacijske aktivnosti. Vrijednosti su iskazane u tekućim cijenama s obzirom na to da je stopa inflacije za razdoblje od 1. 1. 2013. do 1. 1. 2017. godine iznosila -0,15 % [DZS, www.dzs.hr, 18. 3. 2017.].

Tablica 53: Financijski pokazatelji inovacijskih skupina HR NTP 2015 (u tisućama kn)

| Pokazatelji | Ino. skupina | 2013 | 2014 | 2014/13 (%) | 2015 | 2015/14 (%) | 2016 | 2016/15 (%) | 2016/13 (%) |
|--|--------------|------------------|----------------|--------------|----------------|--------------|----------------|--------------|-------------|
| <i>Dodana vrijednost po zaposlenom</i> | V | 86.456 | 89.311 | 3,3 | 87.985 | -1,48 | 82.261 | -6,51 | -4,85 |
| | S | 107.167 | 154.997 | 44,63 | 131.042 | -15,45 | 158.625 | 21,05 | 48,02 |
| | N | 32.179 | 34.219 | 6,34 | 39.842 | 16,43 | 37.937 | -4,78 | 17,89 |
| <i>Prihod od prodaje</i> | V | 310.504 | 293.310 | -5,54 | 308.357 | 5,13 | 282.779 | -8,29 | -8,93 |
| | S | 1.022.828 | 960.793 | -6,07 | 867.954 | -9,66 | 719.941 | -17,05 | -29,61 |
| | N | 155.579 | 142.273 | -8,55 | 150.071 | 5,48 | 130.886 | -12,78 | -15,87 |
| <i>Prihod od prodaje po zaposlenom</i> | V | 801 | 829 | 3,46 | 832 | 0,42 | 873 | 4,86 | 8,94 |
| | S | 898 | 972 | 8,21 | 992 | 2,05 | 911 | -8,13 | 1,45 |
| | N | 1.065 | 978 | -8,21 | 1.024 | 4,7 | 850 | -16,94 | -20,17 |

Napomena: V = inovacijsko vodeći, S = inovacijski sljedbenici, N = neinovativni.

Iznosi u tekućim cijenama.

Izvor: Obrada autora prema podacima FINA-e (2017)

Promatrajući tablicu 53, kao i u prvoj fazi istraživanja na skupinama HR NTP, vidljivo je da skupina inovacijskih sljedbenika bilježi nešto više prosječne pokazatelje. Agregirano gledano, dodana vrijednost po zaposlenome najviša je u skupini inovacijskih sljedbenika. Kod prosječnog prihoda od prodaje i prihoda od prodaje po zaposlenom primjetna je slična distribucija pokazatelja.

U sljedećoj tablici prikazani su pokazatelji profitabilnosti inovacijskih skupina, povrat na prodaju, tj. profitna marža (ROS), povrat na imovinu (ROI), povrat na kapital (ROE) i povrat na investirano (ROI) te pokazatelj ekonomičnosti ukupnog poslovanja.

Tablica 54: Profitabilnost i ekonomičnost inovacijskih skupina HR NTP 2015

| Pokazatelji | Ino. skupina | 2013 | 2014 | 2014/13 (%) | 2015 | 2015/14 (%) | 2016 | 2016/15 (%) | 2016/13 (%) |
|--|--------------|---------------|---------------|-------------|---------------|-------------|---------------|---------------|-------------|
| <i>ROS</i> | V | 2,89 | 4,55 | 57,21 | 5,50 | 20,88 | 12,40 | 125,39 | 328,94 |
| | S | 0,60 | 2,52 | 316,70 | 2,89 | 14,68 | 2,25 | -22,07 | 275,37 |
| | N | -4,73 | -10,23 | - | -3,89 | - | 4,65 | - | - |
| <i>ROA</i> | V | 1,51 | 2,35 | 55,63 | 2,67 | 13,62 | 2,98 | 11,77 | 97,63 |
| | S | 1,86 | 2,6 | 39,78 | 1,98 | -23,85 | 2,32 | 17,24 | 24,80 |
| | N | -1,2 | -2,51 | - | -1,77 | - | 1,92 | - | - |
| <i>ROE</i> | V | 4,78 | 3,89 | -18,62 | 5,11 | 31,36 | 6,60 | 29,11 | 38,02 |
| | S | 20,24 | 8,46 | -58,20 | 4,79 | -43,38 | 5,75 | 20,14 | -71,57 |
| | N | -0,77 | -7,21 | - | 17,46 | - | 0,85 | - | - |
| <i>ROI</i> | V | 5,33 | 4,44 | -16,70 | 5,08 | 14,41 | 6,27 | 23,52 | 17,72 |
| | S | 8,92 | 4,17 | -53,25 | 6,69 | 60,43 | -6,17 | -192,20 | -169,15 |
| | N | -3,62 | -17,4 | - | 10,37 | - | 0,01 | - | -100,38 |
| <i>Ekonomičnost ukupnog poslovanja</i> | V | 103,57 | 105,55 | 1,91 | 106,08 | 0,50 | 107,30 | 1,15 | 3,60 |
| | S | 103,38 | 104,85 | 1,42 | 103,84 | -0,96 | 104,00 | 0,16 | 0,60 |
| | N | 99,35 | 96,46 | -2,91 | 99,24 | 2,88 | 104,88 | 5,68 | 5,56 |

Napomena: V = inovacijsko vodeći, S = inovacijski sljedbenici, N = neinovativni.

Pokazatelji u tekućim cijenama.

Izvor: Obrada autora prema podacima FINA-e (2017)

U razdoblju od 2013. do 2016. godine kod inovacijsko vodećih poduzeća profitna marža (ROS) porasla je za visokih 328,94 % te je značajno viša u cijelom promatranom razdoblju nego kod skupina inovacijskih sljedbenika i neinovativnih HR NTP 2015 (neinovativni do 2016. bilježe negativne pokazatelje). Što se tiče povrata na imovinu (ROA), skupina inovacijsko vodećih poduzeća prikazuje najviše prosječne vrijednosti pokazatelja u zadnje dvije promatrane godine.

Također, jedino kod inovacijsko vodećih poduzeća primjetan je rast u svim godinama koji u konačnici iznosi 97,63 %. Kod ostala dva pokazatelja profitabilnosti, povrata na kapital (ROE) i povrata na investirano (ROI), također je vidljiva značajna razlika u pokazateljima između skupine inovacijsko vodećih i skupina inovacijskih sljedbenika i neinovativnih HR NTP s posebnom naznakom na iznimno visok rast oba pokazatelja u 2016. godini. Pokazatelj ekonomičnosti u sve četiri promatrane godine značajno je viši kod skupine inovacijsko vodećih HR NTP 2015 te u krajnjoj 2016. godini doseže vrijednost od 107,30. Može se zaključiti da je agregirana prosječna vrijednost svih analiziranih pokazatelja profitabilnosti i ekonomičnosti značajno viša kod skupine inovacijsko vodećih poduzeća. Treba naglasiti da je primjetan rast pokazatelja profitabilnosti i ekonomičnosti kod svih skupina zasigurno povezan i s izlaskom iz recesijskog razdoblja u kojemu se Republika Hrvatska nalazila od 2008. godine.

S obzirom na to da su, kao i u prve dvije faze istraživanja, financijski pokazatelji prikazani agregirano za svaku inovacijsku skupinu poduzeća i uzimajući u obzir činjenicu da, relativno govoreći, mali uzorak čine srednje velika i velika poduzeća, čiji pojedinačni pad ili rast može značajno utjecati na agregirane prosječne vrijednosti, u nastavku će se primjenjivati parametrijski ili neparametrijski statistički test za procjenu statistički značajne razlike u financijski izraženoj efikasnosti svih poduzeća unutar HR NTP 2015. Testiranje hipoteze $H13$ izvršit će se na temelju pokazatelja prosječnog rasta (4 godine) za sve financijske pokazatelje.

Pregledom histograma, normal Q-Q plotova, box plotova i Shapiro-Wilkovim testom ($p < 0,05$ za sve varijable) utvrđeno je da podatci inovacijskih skupine poduzeća HR NTP 2015 nisu normalno distribuirani sa z-vrijednostima asimetrije i zaobljenosti izvan intervala $-1,96 - 1,96$, tj. *skewness* (koeficijent asimetrije) od $-4,874$ do $6,532$ (standardna greška (SE) $0,277$) i *kurtosis* (koeficijent zaobljenosti) od $19,495$ do $54,535$ (SE $0,548$). S obzirom na to da se distribucija podataka značajno razlikuje od normalne distribucije, upotrijebljen je Mann-Whitneyjev neparametrijski test za testiranje razlike u rangovima financijske efikasnosti inovacijsko vodećih u odnosu na neinovativna HR NTP 2015 (tablice 55 i 56).

Tablica 55: Mann-Whitneyjev test o financijskoj efikasnosti inovacijsko vodećih i neinovativnih HR NTP 2015

| | <i>Dodana vrijednost po zaposlenom_avg_g</i> | <i>Prihod od prodaje_avg_g</i> | <i>Prihod od prodaje po zaposlenom_avg_g</i> | <i>Broj zaposlenih_avg_g</i> |
|------------------------|--|--------------------------------|--|------------------------------|
| Mann-Whitney U | 122,000 | 105,000 | 134,000 | 101,000 |
| Wilcoxon W | 258,000 | 241,000 | 270,000 | 237,000 |
| Z | -1,770 | -2,256 | -1,428 | -2,370 |
| Asymp. Sig. (2-tailed) | 0,077* | 0,024** | 0,153 | 0,018** |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI); *_avg_g* = prosječni rast
 ** Signifikantnost na razini pouzdanosti od 95 %; * Signifikantnost na razini pouzdanosti od 90 %.

Izvor: Istraživanje autora

Rezultati Mann-Whitneyjeva U-testa potvrđuju ono što je vidljivo iz tablice 53, odnosno postojanje razlike u rangovima sljedećih financijskih pokazatelja inovacijsko vodećih i neinovativnih HR NTP 2015: dodane vrijednosti po zaposlenom_avg_g, prihoda od prodaje_avg_g, i broja zaposlenih_avg_g. Navedeni je test statistički značajan na razini značajnosti $\alpha = 0,05$ (5 %) za dva pokazatelja, prihod od prodaje_avg_g i broj zaposlenih_avg_g. Mann-Whitneyjev test nije statistički značajan za pokazatelj prihod od prodaje po zaposlenom_avg_g, dok se rezultat neparametrijskog testa za varijablu dodana vrijednost po zaposlenom_avg_g na razini značajnosti od 10 % mora uzeti s rezervom.

U tablici 56 prikazani su rezultati Mann-Whitneyjeva testa o razlikama u rangovima profitabilnosti i ekonomičnosti inovacijsko vodećih u odnosu na neinovativna HR NTP 2015.

Tablica 56: Mann-Whitneyjev test o profitabilnosti i ekonomičnosti inovacijsko vodećih i neinovativnih HR NTP 2015

| | <i>ROS_avg_g</i> | <i>ROA_avg_g</i> | <i>ROE_avg_g</i> | <i>ROI_avg_g</i> | <i>Ekonomičnost_avg_g</i> |
|------------------------|------------------|------------------|------------------|------------------|---------------------------|
| Mann-Whitney U | 87,000 | 78,000 | 80,000 | 103,000 | 171,000 |
| Wilcoxon W | 223,000 | 214,000 | 216,000 | 239,000 | 447,000 |
| Z | -2,770 | -3,027 | -2,969 | -2,313 | -,371 |
| Asymp. Sig. (2-tailed) | 0,006*** | 0,002*** | 0,003*** | 0,021** | 0,711 |

Napomena: ^a Grupirajuća varijabla: inovacijska skupina poduzeća (RII, RMI); *_avg_g* = prosječni rast
 *** Signifikantnost na razini pouzdanosti od 99 %; ** Signifikantnost na razini pouzdanosti od 95 %

Izvor: Istraživanje autora


Rezultati Mann-Whitneyjeva U-testa potvrđuju da je navedeni test statistički značajan na razini značajnosti $\alpha = 0,01$ i $\alpha = 0,05$ (1 % i 5 %) za sve pokazatelje profitabilnosti, dok za pokazatelj ekonomičnosti navedeni test nije statistički značajan.

Shodno navedenome, ovim neparametrijskim testovima nije dana potpora (odbacuje se) hipotezi *H13* te se može zaključiti da postoji statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih u odnosu na neinovativna HR NTP 2015.

4.5.5. Model za prijelaz iz neinovativnog u inovativno vodeće poduzeće

U svrhu istraživanja mogućnosti cjelovitog i uspješnog upravljanja inovacijama u hrvatskim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti, a na temelju predloženog modela, nakon opsežne i temeljite teorijske razrade koncepta upravljanja inovacijama u prvim dvjema fazama istraživanja, utvrđena je povezanost između visine i strukture ulaganja u inovacije i inovacijskih rezultata u hrvatskim i njemačkim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti. Također je utvrđena povezanost između inovacijskih rezultata i gospodarske efikasnosti HR NTP i DE NTP. Uz ulazne čimbenike, visinu i strukturu ulaganja, istraženi su uloga i utjecaj procesnih čimbenika, tj. inovacijskih sposobnosti poduzeća te međuovisnost tih dvaju čimbenika. U trećoj su fazi uključeni rezultati istraživanja na njemačkim poduzećima zajedno s drugim relevantnim istraživanjima radi istraživanja mogućeg prijenosa znanja na hrvatska poduzeća. Rezultati empirijske analize iz svih triju faza doprinijeli su oblikovanju modela za cjelovitije i uspješnije upravljanje inovacijama s ciljem prijelaza iz neinovativnog u inovativno vodeće poduzeće (slika 9).

Slika 9: Model za prijelaz iz neinovativnog u inovativno vodeće poduzeće



Izvor: Istraživanje autora

Polazna pretpostavka za kreiranje predloženog modela bila je da, uz ulazne inovacijske čimbenike, visinu i strukturu ulaganja u inovacije i zaposlene na poslovima R&D, na inovacijske rezultate utječu i nefinancijski procesni inovacijski čimbenici, tj. inovacijske sposobnosti poduzeća. Nakon potvrde statistički značajne razlike ulaznih i procesnih inovacijskih čimbenika između promatranih skupina NTP, potvrđen je i pozitivan utjecaj ostalih vrsta inovacija (organizacijske, procesne i marketinške) na razinu inovacija proizvoda. U završnoj statističkoj analizi potvrđena je značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih poduzeća u odnosu na neinovativna poduzeća NTR.

Shodno svemu prethodno navedenome i u skladu s definiranim znanstvenim problemom i predmetom istraživanja, prihvaća se temeljna znanstvena hipoteza (*H0*) i zaključuje da se na temelju znanstveno utemeljenih spoznaja o upravljanju inovacijama, karakteristikama inovacijskog kapaciteta hrvatskih poduzeća, značajkama hrvatskih poduzeća niske i srednje niske tehnološke razine i istraženim inovacijskim čimbenicima njemačkih poduzeća s niskom i srednje niskom tehnološkom razinom može razviti model kojim će se uspješno upravljati inovacijama u hrvatskim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti.

U tablici 57 u nastavku nalazi se sumarni prikaz znanstvenih hipoteza, rezultata testiranja hipoteza te utjecaja na predloženi model za prijelaz iz neinovativnog u inovativno vodeće poduzeće.

Tablica 57: Rezultati testiranja hipoteza i utjecaji na model

| | Hipoteza | Rezultat testiranja | Utjecaj na model |
|----------------------------------|--|---|--|
| F A Z A 1 | <i>H1: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP</i> | <i>H1 se odbacuje i zaključuje se da postoji statistički značajna razlika u visini i strukturi inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP</i> | Empirijsko istraživanje teorijskih pretpostavki na 996 HR NTP; utječe na model kao potpora <i>H8</i> |
| | <i>H2: Ne postoji statistički značajna razlika u visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP</i> | <i>H2 se odbacuje i zaključuje se da postoji statistički značajna razlika u visini i strukturi inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP</i> | Utječe na model kao potpora <i>H8</i> |
| | <i>H3: Ne postoji statistički značajna razlika u efikasnosti inovacijskog procesa inovacijsko vodećih HR NTP u odnosu na inovacijske sljedbenike i neinovativna HR NTP</i> | <i>H3 se odbacuje i zaključuje se da postoji statistički značajna razlika u efikasnosti inovacijskog procesa inovacijsko vodećih HR NTP u odnosu na inovacijske sljedbenike i neinovativna HR NTP</i> | Pokazatelj produktivnosti inovacijskog procesa ne utječe na model |
| | <i>H4: Ne postoji statistička razlika u financijski izraženoj efikasnosti inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna HR NTP</i> | <i>H4 se odbacuje i zaključuje se da postoji statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih HR NTP u odnosu na inovacijske sljedbenike i neinovativna HR NTP</i> | Utječe na model kao potpora <i>H13</i> |
| F A Z A 2 | <i>H5: Na inovacijske rezultate DE NTP osim ulaznih inovacijskih čimbenika (visina i struktura ulaganja u inovacije) ne utječu i procesni inovacijski čimbenici (organizacija i upravljanje inovacijskim procesom)</i> | <i>H5 se odbacuje i zaključuje se da na inovacijske rezultate DE NTP, osim ulaznih inovacijskih čimbenika (visina i struktura ulaganja u inovacije), utječu i procesni inovacijski čimbenici (organizacija i upravljanje inovacijskim procesom)</i> | Empirijsko istraživanje teorijskih pretpostavki na 967 DE NTP; visina i struktura ulaganja u inovacije utječe na model kao potpora <i>H8</i> ; analiza i testiranje procesnih inov. čimbenika utječe na model kao potpora <i>H9</i> i <i>H10</i> |
| | <i>H6: Ulazni inovacijski čimbenici ne utječu značajno na procesne čimbenike DE NTP</i> | <i>H6 se prihvaća i zaključuje se da ulazni inovacijski čimbenici ne utječu značajno na procesne čimbenike DE NTP</i> | Utječe na model kao potpora <i>H9</i> |
| | <i>H7: Ne postoji statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP</i> | <i>H7 se odbacuje i zaključuje se da postoji statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih u odnosu na inovacijske sljedbenike i neinovativna DE NTP</i> | Utječe na model kao potpora <i>H13</i> |

| | Hipoteza | Rezultat testiranja | Utjecaj na model |
|---------------------------|--|--|---|
| F A Z A 3 | <i>H8: Ne postoji statistički značajna razlika u ulaznim inovacijskim čimbenicima (visina i struktura ulaganja u inovacije, zaposleni na poslovima R&D-ja) unutar skupina HR NTP 2015</i> | <i>H8 se djelomično odbacuje i zaključuje se da između skupina inovacijsko vodećih i inovacijskih sljedbenika HR NTP 2015 ne postoji statistički značajna razlika u ulaznim inovacijskim čimbenicima, dok između skupina inovacijsko vodećih i neinovativnih HR NTP 2015 postoji statistički značajna razlika u ulaznim inovacijskim čimbenicima</i> | Utječe na model kao potvrda utjecaja ulaznih inovacijskih čimbenika |
| | <i>H9: Ne postoji statistički značajna razlika u procesnim inovacijskim čimbenicima (inovacijskim sposobnostima) inovacijsko vodećih poduzeća u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015</i> | <i>H9 se odbacuje i zaključuje se da postoji statistički značajna razlika u procesnim inovacijskim čimbenicima (inovacijskim sposobnostima) inovacijsko vodećih poduzeća u odnosu na inovacijske sljedbenike i neinovativna HR NTP 2015</i> | Utječe na model kao potvrda utjecaja procesnih inovacijskih čimbenika, tj. inovacijskih sposobnosti HR NTP 2015 |
| | <i>H10: Inovacijom procesa HR NTP 2015 prosječno štede, povećavaju kvalitetu i pozitivno utječu na razinu inovacija proizvoda</i> | <i>H10 se prihvaća i zaključuje se da inovacijom procesa HR NTP 2015 prosječno štede, povećanjem kvalitete povećavaju prihod i pozitivno utječu na razinu inovacija proizvoda</i> | Utječe na model kao potvrda utjecaja inovacija procesa |
| | <i>H11: Organizacijskim inovacijama te inovacijom poslovnog modela HR NTP 2015 pozitivno utječu na razinu inovacija proizvoda</i> | <i>H11 se prihvaća i zaključuje se da organizacijskim inovacijama te inovacijom poslovnog modela HR NTP 2015 pozitivno utječu na razinu inovacija proizvoda</i> | Utječe na model kao potvrda utjecaja organizacijskih inovacija |
| | <i>H12: Marketinške inovacije HR NTP 2015 pozitivno utječu na razinu inovacija proizvoda</i> | <i>H12 se prihvaća i zaključuje se da marketinške inovacije HR NTP 2015 pozitivno utječu na razinu inovacija proizvoda</i> | Utječe na model kao potvrda utjecaja marketinških inovacija |
| | <i>H13: Ne postoji statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih u odnosu na neinovativna HR NTP 2015</i> | <i>H13 se odbacuje i zaključuje se da postoji statistički značajna razlika u financijski izraženoj efikasnosti inovacijsko vodećih u odnosu na neinovativna HR NTP 2015</i> | Utječe na model kao potvrda važnosti inovacija za uspješnost poslovanja poduzeća |

Izvor: Autor

4.6. Inovacije u hotelijerstvu (H14)

Kako uspješno i održivo djelovati u današnjem dinamičnom, strukturiranom i složenom okruženju postaje sve teže pitanje za turističke djelatnike. Turizam ima vrlo snažan utjecaj na mnogobrojne dionike u okruženju jer, osim što je izvor profita, također je i potencijalan izvor negativnih učinaka na socijalnoj, ekološkoj i ekonomskoj razini. Održivo djelovanje zahtijeva povećanje turističke vrijednosti destinacije kroz strateško upravljanje raspoloživim sredstvima s ciljem stvaranja novih proizvoda i/ili usluga. Proizvodi i usluge moraju sadržavati dodanu vrijednost i za turiste i za sve lokalne dionike (Varra *et al.*, 2012). U posljednje vrijeme sprega između turizma i inovacija postaje sve jača i intenzivnija. Destinacije ne mogu više opstati bez provedbe potrebnih poslovnih inovacija (Huybers, Bennett, 2000). Drugim riječima, izvrsne i konkurentne aktivnosti u sektoru turizma mogu se uspješno održavati isključivo stalnim ulaganjima u znanje i inovacije. Inovacije u turizmu podrazumijevaju proizvode ili usluge, nikad prije viđene ili nove za određenu tvrtku ili destinaciju. Proizvodi i usluge moraju biti vidljivi turistima na razini na kojoj lako mogu postati faktor odlučivanja pri kupnji (Hjalager, 2010).

Promjene su neizbježne i, uz trenutačni tempo tehnologije i razvoja, društvima i poduzećima postaje sve teže kontinuirano inovirati i mijenjati svoje procese. Međutim, menadžeri bi mjerenjem zadovoljstva potrošača i kvalitete usluge upotrebom sadašnje i nadolazeće inovativne tehnologije mogli razviti snažan alat za upravljanje i na taj način stvarati platformu za daljnje poticanje inovacija (Vitezić *et al.*, 2015). Istraživanja su pokazala da inovacije poslovnih modela također mogu biti ključan pokretač uspjeha u osiguravanju konkurentnosti i održivosti, ali za poduzeća je važno da ne stvaraju samo novi poslovni model za inovacije i upravljanje, nego i da to rade odgovorno. Poduzeća bi inovaciju poslovnog modela trebala usmjeriti i prema ispunjenju potrošačke potrebe kao i prema stvaranju održivog modela usluga koji smanjuje upotrebu materijala, a ne smanjuje potražnju potrošača ili sposobnost poduzeća da pruži uslugu (Pavie *et al.*, 2013).

Broj teorijskih studija o inovacijama u turizmu nevjerojatno je mali (Williams, Shaw, 2011), stoga ne iznenađuju i relativno malobrojne studije o inovacijama u hotelijerstvu. Unatoč činjenici da su statističke analize ovog fenomena rijetke, najviše zbog konceptualnih problema

povezanih s karakteristikama usluga, turizma i hotelskih tvrtki te zbog nedostatka dostupnih podataka (Souto, 2015), Jacob *et al.* (2004) identificiraju hotelijerstvo kao najinovativniju industriju u sektoru turizma. Vlasnici i menadžeri hotela imaju priliku zadovoljiti preferencije potencijalnih kupaca kroz prezentaciju novih proizvoda i usluga koji podižu kvalitetu usluge te u konačnici dovode do povećanja prodaje, tržišnog udjela i profita (Chen *et al.*, 2011). Metodološki pristup temelji se na pretpostavci da je stajalište menadžmenta prema inovaciji ili strategiji diferencijacije određeno inovacijskim ponašanjem hotelskog poduzeća koje kasnije utječe na uspješnost poslovanja hotela (npr. Hult *et al.*, 2004; Hurley *et al.*, 2005). Inovacije koje implementiraju hotelska poduzeća bilo koje veličine pozitivno utječu na buduće poslovanje hotela, mjereno u pogledu njihove zauzetosti kapaciteta (Orfila-Sintes, Mattsson, 2009). Hoteli više kategorije imaju višu stopu inovacija, tj. rastuću profitabilnost, što ukazuje na pozitivan odnos između inovativnosti i kategorizacije (Orfila-Sintes *et al.*, 2005). Primjerice, hoteli s jednom zvjezdicom ili dvije zvjezdice prilično zaostaju u uvođenju ICT-a u odnosu na hotele više kategorije. Grissemann *et al.* (2013) stava su da menadžeri i vlasnici hotela s četiri ili pet zvjezdica orijentaciju na gosta smatraju jako važnom za financijski uspjeh hotela, što često nije slučaj kod menadžera hotela s jednim zvjezdicom do tri zvjezdice. Također, Martinez-Ros i Orfila-Sintes (2009) ukazuju na činjenicu da vlasničko upravljanje smanjuje vjerojatnost da će hotelsko poduzeće inovirati inkrementalno ili radikalno. Drugim riječima, radikalne inovacije češće će poticati menadžeri izvan vlasničke strukture negoli sami vlasnici.

Da bi se došlo do zaključka o inovacijskoj aktivnosti i inovacijskim sposobnostima u hotelijerstvu te o mogućoj primjeni modela za uspješno upravljanje inovacijama, s menadžerima „nevlasnicima” hotela visoke kategorije (četiri i pet zvjezdica) proveden je polustrukturirani intervju. Polustrukturirani intervju sastoji se od ukupno 30 pitanja: 24 zatvorena pitanja povezana s inovacijskim sposobnostima hotelskih poduzeća te šest otvorenih pitanja. Otvorena pitanja povezana su s ulaznim i izlaznim inovacijskim čimbenicima i dopuštaju fleksibilnost u sekvencioniranju pitanja, vremenu i pozornosti danoj svakoj temi. Tijekom razgovora sa svim se ispitanicima raspravilo o različitim primjerima i mogućnostima predloženog inovativnog modela.

H14 = Model inovacijskog menadžmenta HR NTP moguće je primijeniti i na uslužna poduzeća – Hotelijerstvo

Uzorak se u ovom kvalitativnim pristupu birao ciljano. Intervjui su provedeni s deset menadžera (četiri direktora kontrolinga, dva direktora operacija, dva direktora marketinga i dva predsjednika uprave) velikih hotelskih grupacija. Riječ je o manjem uzorku, ali o uzorku u kojem ispitanici mogu dati najpouzdanije podatke. Intervjui su provedeni licem u lice ili telefonom zbog geografske udaljenosti u razdoblju između 15. svibnja 2017. i 25. lipnja 2017. Svrha ove metode prikupljanja bila je osigurati istraživanje s visokom stopom odgovora i omogućiti ispitanicima da u potpunosti razumiju pitanja. U najavi intervjuja svim su sudionicima prezentirani svrha i ciljevi istraživanja kao i informacije o povjerljivosti podataka i anonimnosti sudionika. Tijekom svakog intervjuja vodile su se bilješke, a intervjui su u prosjeku trajali 46 minuta – najkraći intervju trajao je 31 minutu, a najduži 75 minuta. Nakon odrađenih intervjuja bilješke su umnožene u nekoliko primjeraka. Originali su pohranjeni, a ostali primjerci služili su kao radni papiri. Svi podaci svrstani su pod zajedničke nazive, tj. kodove. Kodovi su prvotno određeni prema istraživačkim pitanjima. Preciznije, da bi se istražilo vrijedi li postojeći okvir (model) u novim uvjetima obavlja se deduktivno kodiranje. Deduktivni pristup pomaže analizirati jesu li odnosi i uzorci provedenih intervjuja postignuti u općenitom kontekstu. Međutim, tijekom analize uočene su i neke druge grupe podataka koje nisu odgovarale postojećim kodovima te su se kreirali novi. Kodovi su zatim grupirani, tj. integrirani, s pomoću tablične analize. U odjeljcima koji slijede prikazani su sažeti rezultati istraživanja.

Intervjui su većinom započeti činjenicom da su inovacijske aktivnosti u uslužnim djelatnostima formalno manje organizirane te je, s obzirom na to da je R&D slabije definiran u uslužnoj industriji u odnosu na prerađivačku industriju, ponekad posebno teško razlučiti aktivnosti istraživanja i razvoja od ostalih inovacijskih aktivnosti (vidjeti Priručnik iz Frascatija (Frascati Manual), str. 145. – 151., Priručnik iz Osla (Oslo manual)). Svi ispitanici potvrđuju da su hotelska poduzeća prisutna u aktivnostima istraživanja i razvoja. Također, formalni, namjenski R&D odjel nije prepoznat kao takav, već je u hotelima prisutan neformalan ili povremeni R&D koji se izvodi u ostalim odjelima poduzeća. Inovacijom upravljaju ili odjeli pojedinačno ili se formira projektni tim za svaku vrstu inovacije posebno. Odjeli koji zamjenjuju formalni R&D

odjel jesu odjel investiranja, odjel operacija i odjel marketinga. Nadalje, uz vlastite aktivnosti istraživanja i razvoja, menadžeri naglašavaju ulogu vanjske usluge u vidu renomiranih međunarodnih konzultantskih kuća. Također, 8/10 ispitanika potvrdilo je trend porasta ulaganja u inovacijske aktivnosti te porast broja zaposlenika na poslovima istraživanja i razvoja.

Kad je riječ o organizacijskoj sposobnosti kao o procesnom inovacijskom čimbeniku, 9/10 ispitanika potvrdilo je da njihova poduzeća iznimno fleksibilno prilagođavaju organizacijsku strukturu novim inovacijskim projektima, što je i jasno vidljivo iz prethodnog odlomka. Jednak broj ispitanika (9) naglasio je snagu hotelskih poduzeća kroz kapacitet za paralelno upravljanje s više inovacijskih projekata. Svi menadžeri potenciraju sposobnost brze reakcije i prilagodbe zahtjevima vanjskog okruženja, ali istovremeno vide još prostora za napredak. Kad je riječ o odgovornosti zaposlenika, 6/10 ispitanika tvrdi da je ona na zavidnoj razini te da ne nedostaje poticaja zaposlenicima za razvoj novih ideja.

Nastavljajući se na pitanje o poticajima zaposlenicima kao jednim od elemenata sposobnosti strateškog upravljanja, 7/10 ispitanika potvrđuje da njihovo poduzeće ima definiran sustav pokazatelja uspješnosti koji potiče inovacije kroz sustav nagrađivanja. U procesu upravljanja inovacijom, praćenjem, analiziranjem i ocjenjivanjem rezultata, s konkretnim ključnim pokazateljima poslovanja (KPI) bave se odjeli koji i upravljaju inovacijom. Veliku pomoć u praćenju i analizi (ankete, realizacija, planovi, *feasibility* studije, *break even point*) pružaju i odjeli kvalitete i kontrolinga. U kontekstu mogućnosti za napredak, 8/10 ispitanika naglašava sposobnost uspješnog upravljanja intelektualnim kapitalom. Samo su dva ispitanika potvrdila da je inovacijska strategija ugrađena u korporativnu strategiju i planove, ali inovacijska kultura i poticanje razvoja novih ideja na zavidnoj su razini kod 6/10 ispitanika. Svi ispitanici naglašavaju važnost pri zapošljavanju, razvoju, ocjenjivanju i nagrađivanju svojih zaposlenika i potvrđuju sustavnu financijsku potporu inovacijskoj aktivnosti. Prostor za napredak u kontekstu niske razinu autonomije nižeg menadžmenta prepoznat je kod 7/10 ispitanika.

Svi ispitanici naglašavaju veliku važnost marketinške sposobnosti za poslovanje i inovacijsku aktivnost poduzeća. Dugoročni odnosi s potrošačima/gostima s ciljem razumijevanja njihovih različitih zahtjeva te upravljanje i kontrola distribucijske mreže kod 8/10 ispitanika prepoznati

su kao vrlo važni elementi marketinške sposobnosti u koje se iz godine u godinu sve više ulaže. Svi ispitanici slažu se da njihova poduzeća marketinškim aktivnostima povećavaju tržišni udio. Međutim, kod 7/10 ispitanika uočen je prostor za napredak u pogledu sposobnosti učinkovitog predviđanja promjene u preferencijama potrošača.

Osam ispitanika naglašava da ponekad zaostaje u sustavnom praćenju trendova o budućim i tehnologijama u nastajanju povezanim s uslužnim djelatnostima, dok razinu svoje tehnološke opreme smatraju zadovoljavajućima. Unutar informacijske i koordinacijske sposobnosti, svi menadžeri naglašavaju važnost brze i kvalitetne povratne informacije iz odjela koji vodi inovaciju. Dobra koordinacija i suradnja među odjelima operacija, investicija, kvalitete, marketinga i kontrolinga istaknute su kao nužnost za uspješno poslovanje. U većini poduzeća (8/10) ne postoji jasna veza R&D plana s poslovnim planom poduzeća i tehnološkim kompetencijama. Kod svih ispitanika brza implementacija ideje sve do lansiranja na tržište istaknuta je kao ključna sposobnost unutar istraživačko-razvojnog kapaciteta. Pet menadžera naglasilo je sposobnost svojeg poduzeća da brzo preuzima inovacije od drugih te su jednako tako potvrdili da se ponekad razvijaju i vlastita tehnološka rješenja. Zaključno, kod svih ispitanika kreativnost zaposlenika prepoznata je kao pretpostavka za razvoj snažnih istraživačko-razvojnih sposobnosti.

Za potvrđivanje hipoteze *H14* primijenjena je kvalitativna analiza. Pretpostavka za ispitivanje mogućnosti primjene dobivene ocjene kroz model na prerađivačkoj industriji jest pozicija hotelijerstva koje se također svrstava u industriju s nižom tehnološkom razinom, točnije, prema Eurostatovoj (2008) NACE Rev. 2 klasifikaciji uslužnih djelatnosti, u „znanjem niskointenzivnu uslugu” (*Less knowledge-intensive services* – LKIS). Analizom i sintezom rezultata intervjua uočene su sličnosti i razlike u elementima predloženog modela. Rezultati intervjua u skladu su s tvrdnjom Klinea i Rosenberga (1986) o tome da su usluge, po definiciji, interaktivne i skoro su prirodno sklone organizirati svoju inovativnu aktivnost oko interaktivnog modela u kojem djeluju zaposlenici iz različitih odjela.

Dobivene informacije iz polustrukturiranih intervjua upućuju da bi, zadržavanjem ulaznih inovacijskih čimbenika iz predloženog modela za prijelaz iz neinovativnog u inovativno vodeće poduzeće, preformuliranjem i modifikacijom pojedinih procesnih čimbenika, tj. inovacijskih sposobnosti, te usklađivanjem pojedinih izlaznih inovacijskih čimbenika (npr. USALI³⁰ metodom) bilo moguće uspješno upravljati inovacijskim procesima u hotelijerstvu. Na temelju detaljne analize odgovora svih deset visokopozicioniranih menadžera iz velikih hotelskih poduzeća, autor smatra da postoji mogućnost primjene predloženog „modela za uspješno upravljanje inovacijama” na hotelska poduzeća. U skladu s navedenim, može se prihvatiti hipoteza *H14* i zaključiti da je model inovacijskog menadžmenta HR NTP moguće primijeniti i na uslužna poduzeća, tj. hotelijerstvo. Da bi se dale preporuke za daljnje djelovanje i razvoj predloženog modela na uslužnim djelatnostima, potrebno je uspostaviti i dokazati veze između objektivnih pokazatelja uspješnosti poslovanja uslužnih poduzeća i kvantitativnih te kvalitativnih pokazatelja predloženog modela.

³⁰ Općeprihvaćeni standard praćenja rezultata poslovanja u hotelijerstvu

5. ZAKLJUČAK

O odnosu inovacija i gospodarskog razvoja uvelike se raspravlja u literaturi još od Schumpeterovog (1939) doprinosa na poslovnim ciklusima. Na tom okviru zasnovana je i literatura koja tvrdi da nacionalno i zemljopisno okruženje ima veliki utjecaj na način na koji se gospodarski dionici ponašaju i na koji poduzeća posluju (Nelson 1993). Hrvatska srednje velika i velika prerađivačka poduzeća niske i srednje niske tehnološke razine u 2015. godini uložila su 2,70% svojih prihoda u inovacijske aktivnosti što je značajan porast u odnosu na 2012. godinu (0,33% prihoda). Po visini i strukturi ulaganja u inovacijske aktivnosti, prednjače inovacijsko vodeća HR NTP koji ulažu 3,52% svojih prihoda. To je usporedivo s istraživanjem Likar *et al.* (2014a) gdje slovenska inovacijsko vodeća NTP investiraju u inovacijske aktivnosti u prosjeku 3,01% prihoda od prodaje. U skladu s rezultatima istraživanja koja su proveli Račić *et al.* (2005), Heidenreich (2008), Likar *et al.* (2014a) te Hansen i Winther (2014), i ovo istraživanje dokazalo je da u strukturi inovacijskih izdataka HR NTP prevladavaju ulaganja u nabavu postrojenja, opreme, softvera i zgrada nauštrb ulaganja u istraživanje i razvoj, patenata, licenciranja, *know-howa* i obrazovanja, što bi moglo implicirati nešto ograničeniji pogled na inovacije i stvaranje vrijednosti te u konačnici i sporiji razvoj održivih inovacijskih sposobnosti. Međutim, mnoga istraživanja upućuju na važnost takvih ulaganja za konkurentnost poduzeća niske tehnološke razine zbog iznimno značajnog i pozitivnog utjecaja na inovativnost i prodaju (Corbett, 2008; Heidenreich, 2009) te produktivnost (Ghosal, Nair-Reichert, 2009; Kumbhakar *et al.*, 2012). Rastuća sofisticiranost naprednih strojeva postavila je nove zahtjeve pred *low-tech* poduzeća u kontekstu donošenja sve informiranijih odluka o investicijama i promjena u potražnji za radnom snagom, sve više usmjerenoj prema visokostručnim kadrovima (Hollanders, ter Weel, 2002; Mion, Zhu, 2013). Također, s obzirom na strukturu i visinu ulaganja, zaključak je da se većina novih proizvoda razvija vlastitim aktivnostima istraživanja i razvoja što je sukladno istraživanju Likar *et al.* (2014a). Mann-Whitneyjevi neparametrijski testovi o financijskoj efikasnosti inovacijsko vodećih i neinovativnih HR NTP ukazuju na značajnu statističku razliku u prosječnom rastu prihoda, dodane vrijednosti po zaposlenom te prosječnom rastu broja zaposlenih. To nije slučaj s pokazateljem prosječnog rasta prihoda od prodaje po zaposlenom što implicira na porast broja zaposlenih kod inovacijsko vodećih poduzeća što je karakteristično i kod slovenskih poduzeća u istraživanju Likar *et al.* (2014a). Prateći Likar *et al.* (2011)

inovacijsko vodeća slovenska NTP su profitabilnija (najviši ROE, ROA) od inovacijskih sljedbenika i neinovativnih NTP, što je slučaj i kod pokazatelja profitabilnosti (ROS, ROE, ROA i ROI) skupina inovacijsko vodećih i neinovativnih hrvatskih NTP gdje se oni i statistički značajno razlikuju.

Zbog nedostatka R&D aktivnosti poduzeća niske i srednje niske tehnološke razine u posljednje su vrijeme, kada je riječ o inovacijama, često izuzeta iz rasprave. Iako nisu toliko R&D intenzivna, poduzeća NTP i dalje su ekonomska okosnica nekolicine razvijenih industrijskih zemalja u kojima čine jezgru nacionalnog inovacijskog sustava s potencijalno značajnim doprinosom rastu i zapošljavanju. Prerađivačka poduzeća niske i srednje niske tehnološke razine značajni je pokretač i hrvatskoga gospodarstva. Unutar spomenutih poduzeća krije se veliki broj onih koji kreiraju značajan broj novih radnih mjesta te imaju rast brži od prosjeka, ali koja se, zbog osjetljivosti na vanjske faktore iz poslovnog i gospodarskog okruženja, suočavaju sa značajnijim ograničenjima rasta. Rizici su visoki jer poduzeća najčešće nemaju dovoljno kapitala te se uvelike oslanjaju na kratkoročno financiranje poslovnih banaka i investitora. Usprkos ograničenjima, ovo istraživanje potvrdilo je da su hrvatska NTP inovacijski aktivna, što je u skladu s istraživanjem koje su proveli Tipurić *et al.* (2007). Pretpostavka za uspješnu transformaciju i razvoj u skladu za zahtjevima sve dinamičnijeg okruženja jest nužna promjena karaktera poduzeća s niskom i srednje niskom tehnološkom razinom, tj. postupni prelazak iz radno intenzivnih NTP u NTP poduzeća usmjerena k nišama visoke dodane vrijednosti koja ulažu više sredstava u visokokvalificiranu, kreativnu i odgovornu radnu snagu, napredne strojeve te R&D.

Uspoređujući s drugim procesima unutar poduzeća, inovacije i funkcije razvoja proizvoda, usluge, procesa, organizacije ili marketinga imaju složene te iz temelja drugačije izazove. Inovacije i funkcije razvoja dinamički su sustavi s vrlo visoko međusobno povezanim i ovisnim elementima koji stvaraju vrlo malo gotovih proizvoda, usluga, procesa, organizacijskih ili marketinških inovacija. Nakon što inovacijski projekti dosegnu razine zrelosti i budu odobreni, plasiraju se u proces razvoja. Inovacije i razvoj prethodno spomenutih vrsta inovacija imaju veliki potencijal u vidu povećanja produktivnosti te smanjenja troškova. Mjerenje inovacijskog menadžmenta zahtjevna je disciplina i vrlo složeni proces te nije lako definirati i reducirati

mjerljive pokazatelje. Sasvim je očito da je za mjerenje ulaznih čimbenika inovacije potreban drugačiji skup mjernih podataka od onih potrebnih za procesnu i krajnju fazu inovacije. Sposobnost poduzeća da inovira određena je nizom čimbenika koji su povezani s njegovom internom organizacijom i potencijalima kao i s njegovim tržišnim okruženjem. Usto, stvaranje ideje i potom njezino pretvaranje u koristan i tržišno prihvaćen proizvod zahtijeva funkcionalnu unutarnju koordinaciju i integraciju. Konkurentnost turističke destinacije također se može poboljšati boljim razumijevanjem inovacijskih sposobnosti i procesa hotelskih poduzeća koji su vitalni čimbenik svake turističke regije. Poboljšanje percepcije budućih akcija može razviti inovacijsku klimu i stvoriti čitav niz pozitivnih eksternalija za ostatak gospodarstva. „*Inovativnost u organizacijskoj kulturi generira inovativnije ponašanje i ishode, ali inovativnija ponašanja i ishodi također povećavaju inovativnost kulture.*” (Hurley et al., 2005)

Razumijevanje inovativnih ponašanja poduzeća u literaturi je ostalo relativno neuvjerljivo i nedosljedno. Teorijski doprinos doktorske disertacije temelji se na spoznajama o primjenjivosti metodologije inovacijskih aktivnosti poduzeća niže tehnološke razine u kontekstu prerađivačke i hotelske industrije u Hrvatskoj. U domaćoj se literaturi do sada koncept inovacijskog menadžmenta rijetko istraživao, analizirao i mjerio, a jednako tako nije zabilježena primjena modela cjelovitog upravljanja inovacijskim procesima. Takva su istraživanja i u stranoj literaturi veoma rijetka.

Provedena istraživanja u ovom radu žele doprinijeti dosadašnjem znanju teorijskom razradom koncepta upravljanja inovacijama, tj. istraženim vrstama inovacija, inovacijskim procesima po fazama, relevantnim ulaznim, procesnim i izlaznim inovacijskim čimbenicima, menadžerskim alatima i relevantnim čimbenicima od utjecaja na inovacijski kapacitet poduzeća. Za razliku od faze ekonomske ekspanzije kada i neefikasni igrači mogu opstati, pa čak i rasti, na tržištu, gospodarski pad ili recesija nameću se kao intrigantna tema. Ako inovacijski procesi uistinu transformiraju unutarnje sposobnosti pojedinog poduzeća, onda je za očekivati da će se učinci tih transformacija vidjeti tijekom teških razdoblja, tj. razdoblja krize. Prema Geroskom (1993), većini poduzeća, neovisno o tome jesu li ona inovativna, napredak na snažnom i stabilnom tržištu nešto je lakše ostvariv. Međutim, samo određena poduzeća iz skupine inovacijsko aktivnih mogu kontinuirano rasti kada postane „tvrdo”.

Znanstveni doprinos doktorske disertacije predstavljen je u razvijenom modelu inovacijskog menadžmenta koji se temelji na cjelovitom pristupu upravljanja inovacijskim čimbenicima HR NTP. Da bi se oblikovao inovativan model s mogućnošću primjene i na uslužna poduzeća, empirijski je utvrđena pozitivna veza između visine i strukture ulaganja u inovacije i izlaznih pokazatelja inovacija u hrvatskim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti. Jednako tako, istražena je i utvrđena međusobna povezanost pokazatelja inovacijskih ulaganja, pokazatelja upravljanja inovacijskim procesom i inovacijskih rezultata njemačkih poduzeća s niskom i srednje niskom razinom tehnološke razvijenosti. Nadalje, statističkim testovima potvrđena je povezanost između inovacijskih rezultata i gospodarske efikasnosti hrvatskih i njemačkih NTP. Usporedbom rezultata s njemačkim poduzećima istražen je i ostvaren prijenos znanja na hrvatska poduzeća. Eksploratornom faktorskom analizom u trećoj fazi istraživanja izlučeno je šest inovacijskih sposobnosti. Između inovacijsko vodećih i neinovativnih HR NTP postoji statistički značajna razlika u organizacijskoj, marketinškoj, proizvodnoj, istraživačko-razvojnoj, informacijskoj i koordinacijskoj sposobnosti te sposobnosti strateškog upravljanja. Nadalje, hrvatska poduzeća s niskom i srednje niskom razinom tehnološke intenzivnosti inovacijom procesa prosječno štede, povećanjem kvalitete povećavaju prihod i pozitivno utječu na razinu inovacija proizvoda. Također, marketinškim inovacijama, organizacijskim inovacijama te inovacijom poslovnog modela HR NTP pozitivno utječu na razinu inovacija proizvoda.

Iskustvo u inoviranju postaje jedan od najvažnijih pokretača, a istraživanje kroz tri faze upućuje da je ono više kod srednje velikih i velikih poduzeća koja su R&D intenzivnija. Pretpostavka je da poduzeća kroz inovativne procese uče i dalje se razvijaju te primjenjuju taj temelj kako bi ispitala varijacije u inovativnosti poduzeća. Inovativnost se određuje nizom ključnih pokazatelja na ulaznoj, procesnoj i izlaznoj strani inovacija. Shvaćanje činjenice da inovacija nije određena faza u životnom vijeku poduzeća, već neprekidan proces trebalo bi pomoći da se prepoznaju pokretači i prepreke u inoviranju te olakša upravljanje inovacijama u poduzeću (Carayannis, Provan, 2008).

Balansiranje inovacijskih aktivnosti koje ne stvaraju dodanu vrijednost s onim aktivnostima koje je stvaraju predstavlja stalnu borbu za poduzeća svih veličina i svih razina tehnološke intenzivnosti. Rane faze razvoja proizvoda mogu sudjelovati u ukupnim troškovima razvoja s vrlo visokim udjelima. Donošenje ispravne odluke prije nego li su ti troškovi napravljeni može značiti zadovoljavanje potreba kupaca te generiranje ogromne uštede. Uzročnik nesrazmjernog iznosa izgubljenog vremena i truda u razvoju proizvoda često su neispravni inovacijski procesi. Nedostatak sustavne procjene potencijalnih ideja i aktivnosti kao i standardizirani procesi stvaranja proizvoda/usluga nerijetko su glavni čimbenici za gubitke u inovacijskim procesima te procesima razvoja proizvoda/usluga. Sve veća sofisticiranost naprednih strojeva predstavlja velik izazov za NTP u pogledu informiranosti o novim tehnologijama te pravodobnih i pravilnih odluka o ulaganjima. Također, promjene na tržištu rada i potražnja poduzeća za visokokvalificiranom, kreativnom i odgovornom radnom snagom još su jedan od izazova NTP.

Prerađivačka poduzeća niske i srednje niske tehnološke razine značajni su korisnici proizvoda iz *high-tech* sektora. U modernoj ekonomiji poslovanja *high-tech* i *low-tech* sektori jako su međusobno ovisni te bi stoga i politike trebale promatrati gospodarstvo u cjelini. Glavna implikacija iz smjernica budućih politika trebala bi biti mogućnost jasne identifikacije pokretača rasta i produktivnosti na razini poduzeća, a posebno je istaknuta komplementarna uloga inovacija, vještina, vlasništva i kapitalnih ulaganja. Svaki od tih čimbenika ima značajan izravni utjecaj na inovacije i poslovne rezultate, ali također potencijalno utječe i kroz komplementarne efekte zajedno s drugim pokretačima inovacija. Kao što je vidljivo u trećoj fazi istraživanja, kapitalna ulaganja u obliku ulaganja u postrojenja, opremu, softvere i zgrade značajno se povećavaju u hrvatskim prerađivačkim poduzećima niske i srednje niske tehnološke razine. Višestruke studije ukazuju na važnost takvih ulaganja za konkurentnost prerađivačkih NTP jer ona imaju značajno pozitivan utjecaj na produktivnost rada (Hansen, 2014).

Ovaj rad pridonosi menadžerskoj praksi na različitim razinama. Provedena anketa i intervjui vrlo su značajni za kvalitativno i kvantitativno istraživanje jer pružaju “praktičnu potvrdu” menadžera u kontekstu mogućnosti i, prije svega, spremnosti za primjenu inovativnih modela. Pregled literature prema svakom segmentu predloženog modela potvrđuje pozitivan učinak na uspješnost poduzeća. Zaključno, inovacije ili povećavaju vrijednost za kupca našeg proizvoda

ili usluge ili smanjuju troškove te na taj način stvaraju konkurentsku prednost poduzeću. Važno je spoznati da inovaciji treba vremena te donositelji odluka ne bi trebali brzati za zaključcima i “preuveličavati” ključne pokazatelje poslovanja (KPI). Inovacije su suštinski socijalni proces koji se ne vezuje isključivo uz invenciju, već i uz uvjeravanje ljudi da rade nešto na novi način. Poduzeća koja su “inovacijski uporna“ razvijaju rutine (Martinez-Ros, Labeaga, 2009) i inovacijske sposobnosti među svojim odjelima i zaposlenicima, te samim tim povećavaju vjerojatnost uspjeha.

Prepoznato je nekoliko ograničavajućih čimbenika za opravdanu generalizaciju rezultata. Jedno od ograničenja jest veličina uzorka u odnosu na populaciju te njegova struktura. Neto veličina uzorka bila je relativno mala s obzirom na broj varijabli u istraživačkom modelu. Možda bi veći uzorak dao više robusnosti i snage statističkim testiranjima, međutim teškoće pri prikupljanju primarnih podataka na izvršnoj razini, posebno kroz upitnik koji se sastojao od ukupno 35 pitanja u 10 cjelina (120 varijabli), nameću ograničenja složenosti i opširnosti samog mjernog instrumenta. Slično tome, neka druga razina u hijerarhiji poduzeća (npr. srednji menadžment), uz izvršnu razinu s koje su ispitanici odgovarali, može imati različita mišljenja o inovativnoj sposobnosti poduzeća. U trećoj fazi istraživanja struktura poduzeća unutar inovacijskih skupina zbog manjeg uzorka relativno odstupa od strukture uzorka iz sekundarnih podataka u prvim dvjema fazama istraživanja. Ograničenja u istraživanju pri generaliziranju rezultata i prijenosa znanja između njemačkih i hrvatskih poduzeća također su moguća zbog nejednake razvijenosti i različite strukture hrvatskoga i njemačkoga gospodarstva kao i ostalih značajnih čimbenika (kulturološki, sociološki, organizacijski i dr.). Također, ograničavajuć su faktor i, relativno govoreći, zastarjeli podatci iz preliminarne druge faze istraživanja (faze potvrđivanja teoretskih pretpostavki), tj. MIP 2011 upitnika. Treba napomenuti da je riječ o podacima o inovacijskoj aktivnosti poduzeća u Njemačkoj koja je prepoznata i priznata kao jedan od globalnih lidera u području inovacija. Podatci se odnose na trogodišnje razdoblje (2008. – 2010.), a dostupni su, nažalost, postali tek u drugoj godini nakon završne promatrane godine (u ovom slučaju je to 2012. godina). Kako je riječ o panel-podacima, u svakom novom upitniku uz „jezgru“ istih pitanja (sukladno CIS metodologiji) postavljaju se i setovi pitanja koja se povezuju sa specifičnostima inovacijskih aktivnosti poduzeća. Naime, iako je u trenutku analize i obrade sekundarnih podataka dostupno bilo još jedno vremensko razdoblje nakon promatranog, jedino

su podaci MIP 2011 sadržavali set pitanja iz domene inovacijskog menadžmenta, točnije pitanja o inovacijskim sposobnostima poduzeća.

Multidimenzionalni i holistički pristup mjerenju inovacijskog procesa ima potporu u znanstvenoj literaturi, no činjenica je da postoje i razlike u mišljenjima oko uključenih dimenzija i pokazatelja. Iako su u ovom istraživanju odabrana poduzeća niske i srednje niske tehnološke razine, odabir pokazatelja može biti specifičan za svako poduzeće i djelatnost pojedinačno te ovisi o čitavu nizu čimbenika. Njihova važnost varira i ovisno o tehnološkim rješenjima kao i o specifičnosti proizvoda koji se nude. Takve neizvjesnosti upućuju na dodatna područja koja treba istražiti. Fokusiranjem na odabrani skup bitnih varijabli pokušali su se analizirati temeljni aspekti inovacijskih procesa, no činjenica je da je obuhvaćen samo jedan dio vrlo složenog pitanja. Ipak, sintezom triju inovacijskih čimbenika (ulazni, procesni i izlazni) ovaj rad značajno utječe na naprednije razumijevanje višeslojnih veza unutar inovacijskog menadžmenta.

Predugo vrijeme razvoja, nedostatak odgovarajućeg financiranja, nemogućnost pravilnog mjerenja rezultata, nedostatak kvalificiranih kadrova, problem sa selektiranjem pravih ideja za komercijalizaciju i sustav nagrađivanja koji nije povezan s inovacijskim rezultatima najčešće su prepreke s kojima se hrvatska poduzeća susreću pri inoviranju. Analiza svake pojedinačne prepreke poticaj je za daljnja istraživanja u ovom području. Također, buduća istraživanja trebaju nastaviti ispitivati ulogu vodstva u procesu inovacija. Očigledna je uloga top menadžmenta u inovacijama. Izvršni direktori i menadžeri, koji su u stanju stvoriti nova interna znanja kao i nove primjene toga znanja na vanjskom tržištu, učinkovitije utječu na produktivnost inovacija. Istraživanje novih ideja, preuzimanje rizika i iskorištavanje ljudskog i društvenog kapitala dimenzije su vodstva koje poboljšavaju sposobnosti poduzeća za provođenjem osnovnih istraživačkih programa (znanosti), što zauzvrat može dovesti do utjecajnijih inovacija (Makri, Scandura, 2010). Također, prijedlog je da buduća istraživanja ispituju doprinos timova u inovacijskom procesu, osobito povezanost i podudarnost u stilovima upravljanja uprava i menadžerskih timova i količine i kvalitete inovacija.

Za analizu inovacijske aktivnosti poduzeća potreban je visok stupanj upornosti. Prema istraživanjima, visok postotak inovacijsko aktivnih prerađivačkih i uslužnih poduzeća ostaje

inovativan i u sljedećim vremenskim razdobljima te se samim time za buduća istraživanja javlja velika potreba za panel-podacima za istraživanje industrijske dinamike i inovacijske aktivnosti poduzeća. Rezultati analize te razvijeni model također mogu biti polazna točka za učinkovitija istraživanja inovacijskih uzoraka u uslužnim djelatnostima. Također, dobiveni rezultati osnova su za buduća istraživanja i suradnju među državama sličnih inovacijskih kapaciteta (Slovenija i zemlje unutar i izvan EU-a). U konačnici, predloženi model za uspješno upravljanje inovacijama u hrvatskim poduzećima s niskom i srednje niskom razinom tehnološke razvijenosti može biti temelj za daljnja istraživanja na ostalim hrvatskim poduzećima (veličina, tehnološka razina) s ciljem jačanja njihove inovacijske aktivnosti, povećanja ulaganja u istraživanje i razvoj te osnaživanja inovacijskih kapaciteta.

LITERATURA

1. Abernathy, W. J. (1978). *The Productivity Dilemma*. Baltimore: Johns Hopkins University Press
2. Adams, R, Bessant, J., & Phelps, R. (2006). Innovation management measurement: A review. *International Journals of management Reviews*, 8 (1), pp. 21-47.
3. Albaladejo, M., & Romijn, H. (2000). Determinants of innovation capability in small UK firms: an empirical analysis. Working Paper 00.13, Eindhoven Centre for Innovation Studies, Eindhoven.
4. Alpkan, L., Bulut, C., Gunday, G., Ulusoy, G., & Kilic, K. (2010). Organizational support for entrepreneurship and its interaction with human capital to enhance innovative performance. *Management Decision*, 48 (5), pp. 732-755.
5. Amabile, T. M., Conti, R., Coon, H., Lazenby, J., & Herron, M. (1996). Assessing the work environment for creativity. *Academy of management journal*, 39 (5), pp. 1154-1184.
6. Ambrosini, V., Bowman, C., & Collier, N. (2009). Dynamic capabilities: An exploration of how firms renew their resource base. *British Journal of Management*, 20, pp. 9–24.
7. Andrew, J. P., Haanaes, K., Michael D. C., Sirkin, H. L., & Taylor, A. (2009). *Measuring Innovation 2009: The Need for Action*, A BCG Senior Management Survey, The Boston Consulting Group Inc. Boston.
8. Andrew, J. P., Manget, J., Michael D. C., Taylor, A., & Zablitz, H. (2010). *Innovation 2010: A Return to Prominence – and the Emergence of a New World Order*, A BCG Senior Management Survey, BCG Report, The Boston Consulting Group Inc. Boston.
9. Albury, D. (2005). Fostering Innovation in Public Services. *Public Money & Management*, 25 (1), pp. 51-56.

10. Arundel, A., Bordoy, C., & Kanerva, M. (2008). *Neglected innovators: How do innovative firms that do not perform R&D innovate?* Results of an analysis of the Innobarometer 2007 survey No. 215, INNO-Metrics Thematic Paper.
11. Axtell, C. M., Holman, D. J., Unsworth, K. L., Wall, T. D., & Waterson, P. E. (2000). Shopfloor innovation: Facilitating the suggestion and implementation of ideas. *Journal of Occupational and Organizational Psychology*, 73, pp. 265-285.
12. Bailetti, A. J., & Litva, P. F. (1995). Integrating customer requirements into *product designs*. *Journal of Product Innovation Management*, 12 (1), pp. 3-15.
13. Barney, J. (1991). Firm resource and sustained competitive advantage. *Journal of Management*, 17 (1), pp. 99-120.
14. Baregheh A., Rowley J., & Sambrook S. (2009). Towards a Multidisciplinary Definition of Innovation. *Management Decision*, 47 (8), pp. 1323–1339.
15. Bartlett, D., & Trifilova, A. (2010). Green technology and eco-innovation: Seven case-studies from a Russian manufacturing context. *Journal of Manufacturing Technology Management*, 21(8), pp. 910-929.
16. Birkinshaw, J., Hamel, G., & Mol, M. J. (2008). Management innovation. *Academy of management Review*, 33 (4), pp. 825-845.
17. Bottazzi, G., Secchi, A., & Tamagni, F. (2014). Financial constraints and firm dynamics. *Small Business Economics*, 42 (1), pp. 99-116.
18. Brown, S. L., & Eisenhard, K. M. (1995). Product development: Past research, present findings, and future directions. *Academy of Management Review*, 20, pp. 343–378.
19. Bain, P. G., Mann, L., & Pirola-Merlo, A. (2001). The innovation imperative: The relationships between team climate, innovation, and performance in research and development teams. *Small Group Research*, 32, pp. 55-73.

20. Bas T.G., & Kunc M.H. (2009). National Systems of Innovations and Natural Resources Clusters: Evidence from Copper Mining Industry Patents // *European Planning Studies*, 17 (12), pp. 1861–1879.
21. Berry, M. M. J., & Taggart, J. H. (1998). Combining technology and corporate strategy in small high tech firms. *Research Policy*, 26, pp. 883–895
22. Bessant J., & Tidd, J. (2007). *Innovation and Entrepreneurship*. Chichester: John Wiley
23. Bessant, J., & Francis, D. (1997). Implementing the new product development process. *Technovation*, 17, pp. 189–197.
24. Bhartesh, K.R., & Bandyopadhyay, A.K. (2005). Intellectual capital: concept and its measurement. *Finance India*, 19 (4), pp. 1365-674.
25. Birkinshaw, J., Hamel, G., & Mol, M. (2008), Management innovation. *Academy of Management Review*, 33 (4), pp. 825–845.
26. Bowen, H. K., Clark, K. B., Holloway, C. A., & Wheelwright, S. C. (1994). *The Perpetual Enterprise Machine*. Oxford University Press, New York.
27. Boyer, K.K., Lewis, M.W., 2002. Competitive priorities: investigating the need for trade-offs in operations strategy. *Production and Operations Management*, 11 (1), pp. 9–20.
28. Brown, M. G., & Svenson, R. A. (1988). Measuring R&D productivity. *Research-Technology Management*, July–August, pp. 11–15.
29. Buble, M., Kulović, D., Kuzman, S., & Koletnik, F. (2010). *Due diligence i procjena vrednosti poduzeća*. Kemigrafika.
30. Caloghirou, Y., Protogerou, A., & Tsakanikas, A. (2014). Exploring knowledge-intensive entrepreneurship in high-tech and low-tech manufacturing sectors: differences and similarities, in *Knowledge-Intensive Entrepreneurship in Low-Tech Sectors: The Prospects of Traditional Economic Industries*, H. Hirsch-Kreinsen and I. Schwinge (eds.), Edward Elgar Publishing, UK.

31. Canibano, L., Garcia-Ayuso, M., & Sanchez, P. (2000). Accounting for intangibles: a literature review. *Journal of Accounting Literature*, 19, pp. 102-30.
32. Carayannis, E. G., Gonzalez, E., & Wetter, J. (2003). The nature and dynamics of discontinuous and disruptive innovations from a learning and knowledge management perspective. *The international handbook on innovation*, (Part II).
33. Carayannis, E. G., Popescu, D., Sipp, C., & Stewart, M. (2006). Technological learning for entrepreneurial development (TL4ED) in the knowledge economy (KE): case studies and lessons learned. *Technovation*, 26 (4), pp. 419-443.
34. Carayannis, E. G., & Provan, M. (2008). Measuring firm innovativeness: towards a composite innovation index built on firm innovative posture, propensity and performance attributes. *International Journal of Innovation and Regional Development*, 1(1), pp. 90-107.
35. Carlsson B., Keane P., & Martin J.B. (1976). R and D Organizations as Learning Systems. *Sloan Management Review*, 17 (3), pp. 1–15.
36. Carlsson B., Jacobsson S., Holmen M., & Rickne A. (2002). Innovation Systems: Analytical and Methodological Notes. *Research Policy*, 31 (2), pp. 233–245.
37. Carton, R. B., & Hofer, C. W. (2006). *Measuring Organization Performance-Metrics for Entrepreneurship and Strategic Management Research*. Edward Elgar Publishing Limited
38. Cattell, R. B. (1966). The scree test for the number of factors. *Multivariate Behavioral Research*, 1, pp. 245-276.
39. Cavusgil, S. T., Calantone, R. J. & Zhao, Y. (2003). Tacit knowledge transfer and firm innovation capability, *Journal of Business and Industrial Marketing*, 18 (1), pp. 6-21.
40. Chandler, A. D. (1992). Organizational capabilities and the economic history of the industrial enterprise. *Journal of Economic Perspectives*, 6 (3), pp. 79-100.

41. Chang, Y. C, Chang, H. T., Chi, H. R., Chend, M. H., & Denge, L. L. (2012). How do established firms improve radical innovation performance? The organizational capabilities view, *Technovation*, 32, pp. 441–451.
42. Chave, M., Ozier-Lafontaine, H., & Noel Y. (2012). Towards Agricultural Innovation Systems: Designing an Operational Interface. *Outlook on Agriculture*, 41(2), pp. 81–86.
43. Chen, C. J. (2004). The effects of knowledge attribute, alliance characteristics, and absorptive capacity on knowledge transfer performance. *R&D Management*, 34, pp. 311–321.
44. Chen, W. J. (2011). Innovation in hotel services: culture and personality, *International Journal of Hospitality Management*, 30 (1), pp. 64-72.
45. Chen, C. J., Huang, J. W., & Hsiao, Y. C. (2010). Knowledge management and innovativeness: The role of organizational climate and structure. *International Journal of Manpower*, 31 (8), pp. 848-870.
46. Chen, G., Tjosvold, D., & Liu, C. (2006). Cooperative goals, leader people and productivity values: Their contribution to top management teams in China. *Journal of Management Studies*, 43, pp. 1177-1200.
47. Chesbrough, H. W. (2003). *Open Innovation: The New Imperative for Creating and Profiting from Technology*. Harvard Business School Press, Boston.
48. Chesbrough, H. W. (2006). *Open Innovation: Researching a New Paradigm*. New York: Oxford University Press.
49. Chesbrough, H. W. (2007). Business model innovation: it's not just about technology anymore. *Strategy & Leadership*, 35 (6), pp. 12-17.
50. Chiesa, V., Coughlan, P., & Voss, C. A. (1996). Development of a technical innovation audit. *Journal of product innovation management*, 13 (2), pp. 105-136.

51. Christiansen, C. (1997). *The innovator's dilemma*. Harvard Business School Press, Boston.
52. Christiano, L. J., Martin S. Eichenbaum, M. S., & Trabandt, M. (2015). Understanding the Great Recession. *American Economic Journal: Macroeconomics*, 7 (1), pp. 110-67.
53. Cho, H. J., & Pucik, V. (2005). Relationship between innovativeness, quality, growth, profitability and market value. *Strategic Management Journal*, 26, pp. 555–575.
54. Church, R., Hecox, W., Dresner's, S., & Edwards, A. (2008). Sustainable development: oxymoron? Or opposed by morons. *Sustainable Development-EV*, 141.
55. Cleveland, G., Schroeder, R. G., & Anderson, J. C. (1989). A Theory of Production Competence. *Decision Sciences*, 20 (4), pp. 655–668
56. Cockburn, I. M., MacGarvie, M. J., & Mueller, E. (2010). Patent thickets, licensing and innovative performance. *Industrial and Corporate Change*, 19 (3), pp. 899-925.
57. Coenen L., & Lopez F. J. D. (2010). Comparing Systems Approaches to Innovation and Technological Change for Sustainable and Competitive Economies: An Explorative Study into Conceptual Commonalities, Differences and Complementarities. *Journal of Cleaner Production*, 18 (12), pp. 1149–1160.
58. Cooper, R. G., Edgett, S. J., & Kleinschmidt, E. J. (2004). Benchmarking best NPD practices. *Research- Technology Management*, 47, pp. 50–59.
59. Cooper, R. G., Edgett, S. J., & Kleinschmidt, E. J. (1999), New product portfolio management: practices and performance. *Journal of Product Innovation Management*, 16, pp. 333–351.
60. Corbett, L. M. (2008). Manufacturing strategy, the business environment, and operations performance in small low-tech firms. *International Journal of Production Research*, 46, pp. 5491–5513.

61. Costello, A. B., Osborne, J. W. (2005). Best Practices in Exploratory Factor Analysis: Four Recommendations for Getting the Most from Your Analysis. *Practical Assessment, Research & Evaluation*. 10 (7), pp. 1-9.
62. Cronbach, L. J. (1951). Coefficient alpha and the internal structure of tests. *Psychometrika*. 16, pp. 297-333.
63. Cronbach, L. J. (1990). *Essentials of psychological testing*. 26, 5th ed., New York: Harper & Row.
64. Crosby, P.B. (1990). *Vječno uspješna organizacija, umijeće rukovođenja*, Privredni Vjesnik, Zagreb.
65. Cuervo-Cazurra, A., & Un, C. A. (2010). Why some firms never invest in formal R&D. *Strategic Management Journal*, 31 (7), pp. 759–779.
66. Czarnitzki, D., & Kraft, K. (2004). Firm leadership and innovative performance: Evidence from seven EU countries. *Small Business Economics*, 22, pp. 325–332.
67. Czarnitzki, D., & Thorwarth, S. (2012). Productivity effects of basic research in low-tech and high-tech industries. *Research Policy*, 41, pp. 1555–1564.
68. Damanpour, F. (1991), Organizational innovation: a meta-analysis of effects of determinants and moderators. *Academy of Management Journal*, 34, 555– 590.
69. Damanpour, F., & Evan, W. M. (1984), Organizational innovation and performance: The problem of organizational lag. *Administrative Science Quarterly*, 29: 392–40
70. Damanpour, F., Aravind, D. (2012). Managerial Innovation: Conceptions, Processes, and Antecedents, *Management and Organization Review*, 8 (2), pp. 423-454.
71. Danneels, E. (2002). The dynamics of product innovation and firm competences. *Strategic Management Journal*, 23 (12), pp. 1095-1121.
72. Davila, T., Epstein, M. J., & Shelton, R. (2006). *Making innovation work: How to manage it, measure it, and profit from it?* Upper Saddle River, NJ: Pearson Education

73. Davenport, T. H. (1993). *Proces Innovation: Reengineering Work through Information Technology*, Boston: Harvard Business School Press.
74. Day, G. (1990). *Market Driven Strategy: Processes for Creating Value*. Free Press: New York.
75. Day, G. (1994). The capabilities of market-driven organizations. *Journal of Marketing*, 58, pp. 37–52.
76. De Jong, J., & den Hartog, D. (2010). Measuring innovative work behavior. *Creativity and Innovation Management*, 19, pp. 23-36.
77. Delen, D., Kuzey, C., & Uyar, A. (2013). Measuring firm performance using financial ratios: A decision tree approach, *Expert System with Applications*, 40, pp. 3970-3983.
78. Den Hertog, P. (2010). *Managing service innovation: firm-level dynamic capabilities and policy options*. Utrecht: Dialogic Innovatie & Interactie.
79. Denti, L. (2011). *Leadership and Innovation: How and When do Leaders Influence Innovation in R&D Teams?* University of Gothenburg. Sweden
80. Denti (2013). Measuring Innovation part 1: Frequently Used Indicators. Dostupno na <http://www.innovationmanagement.se/2013/02/15/measuring-innovation-part-1-frequently-used-indicators/> [Pristup 20.4. 2016.].
81. Deshpande, R., Farley, J. U., & Webster, F. E. (1993). Corporate culture, customer orientation, and innovativeness in Japanese firms: A quadrad analysis. *Journal of Marketing*, 57, pp. 23–37.
82. Dewangan, V., & Godse, M. (2014). Towards a holistic enterprise innovation performance measurement system, *Technovations*, doi: 10.1016/j.technovation.2014.04.002i
83. Drucker, P. (1985). *Entrepreneurship and innovation: Practice and principles*. NY: Harper Business.

84. Drucker, P. (1999). *Management Challenges for 21st Century*, New York.
85. Durán-Vázquez, R., Lorenzo-Valdés, A., & Moreno-Quezada, G.E. (2012). Innovation and CSR impact on financial performance of selected companies in Mexico, *Journal of Entrepreneurship, Management and Innovation*, 8(3), pp. 5-20.
86. Duschl, M., & Peng, S. S. (2015). The patterns of Chinese firm growth: a conditional estimation approach of the asymmetric exponential power density. *Industrial and Corporate Change*, 24(3), pp. 539-563.
87. Dutta, S., Narasimhan, O., & Rajiv, S. (1999). Success in High-Technology Markets: Is Marketing Capability Critical? *Marketing Science*, 18 (4), pp. 547–568.
88. Edquist, C., Hommen, C. L., & McKelvey, M. (2001). *Innovation and employment: Process versus product innovation*. Cheltenham: Edward Elgar.
89. Eisenhardt, K. M., & Martin, J. A. (2000). Dynamic capabilities: What are they? *Strategic Management Journal*, 21(10/11, Special Issue: The Evolution of Firm Capabilities), pp. 1105–1121.
90. Elenkov, D. S., & Manev, I. M. (2009). Senior expatriates leadership's effects on innovation and the role of cultural intelligence. *Journal of World Business*, 44, pp. 357–369.
91. Ernkvist, M. (2008). Down many times but still playing the game: Creative destruction and industry crashes in the early video game industry pp. 1971-1986. In: Gratzner, K., Stiefel, D. (Eds.), *History of Insolvency and Bankruptcy from an International Perspective*. Södertörns högskola, Stockholm, pp. 161–192.
92. European Commission. (2008). *A More Research- Intensive and Integrated European Research Area*. Brussels: European Commission.
93. European Commission (2010). *EU Manufacturing Industry: What are the Challenges and Opportunities for the Coming Years?* Dostupno na <http://ec.europa.eu/enterprise/policies/industrial-competitiveness/economic->

- crisis/files/eu_manufacturing_challenges_and_opportunities_en.pdf, [Pristup
23.5.2016.].
94. European Commission. (2011). European Industrial Structure: Trends and Performances. Dostupno na
http://ec.europa.eu/enterprise/newsroom/cf/_getdocument.cfm?doc_id57066 [Pristup
28.5.2016].
95. Eurostat (2008). *NACE Rev. 2. Statistical classification of economic activities in the European Community*. Eurostat Methodologies and Working papers. Luxembourg: European Commission.
96. Eurostat (2013). Seventh Community Innovation Survey, Highest proportions of innovative enterprises in Germany, Luxembourg and Belgium, http://europa.eu/rapid/press-release_STAT-13-5_en.htm, [Pristup 14.3.2014.].
97. Evans, P., & Wolf, B. (2005). Collaboration rules. *IEEE Engineering Management Review*, 33 (4), pp. 50-57.
98. Eveleens, C. (2010). Innovation management; a literature review of innovation process models and their implications. *Science*, 800, pp. 1-16.
99. Fabrigar, L. R., Wegener, D. T., MacCallum, R. C., & Strahan, E. J. (1999). Evaluating the use of exploratory factor analysis in psychological research. *Psychological Methods*, 4 (3), pp. 272-299.
100. Fan, T. P. C. (2009). Determinants of de novo new entrant survival in the liberalized intra-European scheduled passenger airline industry. *Transport Research Part E: Logistics and Transportation Review*, 45 (2), pp. 293–306.
101. Fagerberg, J., Mowery, D. C., & Nelson, R. R. (2004). *The Oxford Handbook of Innovation*. Oxford University Press, USA.

102. Felberg, J. D., & DeMarco, D. A. (1992). New idea enhancement at Amoco chemical: An early report from a new system. *Journal of Product Innovation Management*, 9, pp. 278-286.
103. Ferrari, M., La Rocca, L. (2010). Innovation and Performance: Some evidence from Italian firms, pp. 115-141. u knjizi Epstein, M. J., Manzoni, J. F., Davila, A., Performance Measurement and Management Control: Innovative Concepts and Practices, Emerald Group Publishing Limited.
104. Filippetti, A., & Archibugi, D. (2011). Innovation in times of crisis: National Systems of Innovation, structure, and demand. *Research Policy*, 40(2), pp. 179-192.
105. Fingleton, J. (2009). Competition policy in troubled times. *Mercato Concorrenza Regole*, pp. 7-22.
106. Freeman, C. (1974). *The Economics of Industrial Innovation*, Harmondsworth: Penguin Books.
107. Freeman, C. (1982). *The Economics of Industrial Innovation*, 2nd edn. Frances Pinter, London revolution, Oxford University Press.
108. Gamal, D., Salah, T., & Elrayyes, E. N. (2011). How to measure organization Innovativeness. *Technology Innovation and Entrepreneurship Center*.
109. García-Morales, V. J., Mathías-Reche, F., & Hurtado-Torres, N. (2008). Influence of transformational leadership on organizational innovation and performance depending on the level of organizational learning in the pharmaceutical sector. *Journal of Organizational Change Management*, 21, pp. 188–212.
110. Gee S., McMeekin A. (2011). Eco-innovation Systems and Problem Sequences: the contrasting cases of US and Brazilian biofuels. *Industry and Innovation*, 18 (3), pp. 301–316.
111. Geroski, P (1990). Innovation, Technological Opportunity, and Market Structure, *Oxford Economic Papers*, 42, pp. 586-602.

112. Ghosal, V., & Nair-Reichert, U. (2009). Investments in modernization, innovation and gains in productivity: evidence from firms in the global paper industry, *Research Policy*, 38, pp. 536–547.
113. Gilchrist, S., & Sim, J. W. (2007). Investment During The Korean Financial Crisis: A Structural Econometric Approach. *Working Papers Series WP2007-001*, Boston University - Department of Economics.
114. Gilson, L. L., & Shalley, C. E. (2004). A little creativity goes a long way: An examination of teams' engagement in creative processes. *Journal of management*, 30 (4), pp. 453-470.
115. Girotra, K., & Netessine, S. (2014). Four Paths to Business Model Innovation. *Harvard Business Review*, July-August, <https://hbr.org/2014/07/four-paths-to-business-model-innovation>, [Pristup 20.3.2017.].
116. Gokhberg L., Kuznetsova T., & Roud V. (2012). Exploring Innovation Modes of Russian Companies: What Does the Diversity of Actors Mean for Policymaking? HSE Working papers, Series: Science, Technology and Innovation, WP BRP 01/STI/2012. Moscow: National Research University Higher School of Economics. Retrived from: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2156347
117. Godin B. (2006). The Linear Model of Innovation – The Historical Construction of an Analytical Framework. *Science Technology & Human Values*, 31 (6), pp. 639– 667.
118. Grisseemann, U., Plank, A., & Brunner-Sperdin, A. (2013). Enhancing business performance of hotels: The role of innovation and customer orientation, *International Journal of Hospitality Management*, 33, pp. 347-356.
119. Guan, J., & Ma, N. (2003). Innovative capability and export performance of Chinese firms. *Technovation*, 23 (9), pp. 737-747.
120. Guan, J. C., Yam, R. C., Mok, C. K., & Ma, N. (2006). A study of the relationship between competitiveness and technological innovation capability based on DEA models. *European Journal of Operational Research*, 170 (3), pp. 971-986.

121. Gumusluoglu, L., & Ilsev, A. (2009). Transformational leadership and organizational innovation: The roles of internal and external support for innovation. *Journal of Product Innovation Management*, 26, pp. 264–277.
122. Hagedoorn, J., & Cloudt, M. (2003). Measuring innovative performance: is there an advantage in using multiple indicators? *Research policy*, 32 (8), pp. 1365-1379.
123. Hansen, M. T., & Birkinshaw, J. (2007). The innovation value chain. *Harvard business review*, 85 (6), p. 121.
124. Hansen, T., & Winther, L. (2011). Innovation, regional development and relations between high- and low-tech industries. *European Urban and Regional Studies*, 18 (3), pp. 321–339.
125. Hansen, T., & Winther, L. (2014). Competitive low-tech manufacturing and challenges for regional policy in the European context—lessons from the Danish experience. *Cambridge Journal of Regions, Economy and Society*, 7, pp. 449–470.
126. Hamel, G. (2006). *The why, what and how of management innovation*. Harvard Business Review, 84 (2), pp. 72–84.
127. Hanna, V. (2007). Exploiting complementary competencies via inter-firm cooperation. *International Journal of Technology Management*, 37(3-4), pp. 247–260.
128. Hatzichronoglou, T. (1996). Globalisation and Competitiveness: Relevant Indicators, OECD Science, *Technology and Industry Working Papers*, No. 1996/05, OECD Publishing, Paris.
129. Hayes, R. H., & Wheelwright, S. C. (1984). Matching process technology with production/market requirements, u Hayes, R. H., & Wheelwright, S. C. (ured.) Restoring our competitive edge, New York, Wiley.
130. Hayes, R.H., Wheelwright, S.C., Clark, K. (1988). *Dynamic Manufacturing*. The Free Press, New York

- 131.Heger, D. (2004). The Link Between Firms? Innovation Decision and the Business Cycle: An Empirical Analysis, ZEW Discussion Papers, No. 04-85, <http://hdl.handle.net/10419/24092>.
- 132.Heidenreich, M. (2008). Low-tech Industries between Trade and Untraded Interdependencies: a dynamic concept of industrial complementarities. *Innovation in Low-Tech Firms and Industries, Industrial Dynamics, Entrepreneurship and Innovation Series*, Edward Elgar, Cheltenham, pp. 221-244.
- 133.Heidenreich, M. (2009). Innovation patterns and location of European low-and medium- technology industries. *Research Policy*, 38 (3), pp. 483–494.
- 134.Helfat, C. E., Peteraf, M. A. (2003). The dynamic resource-based view: Capability lifecycles. *Strategic Management Journal*, 24 (10), pp. 997– 1010.
- 135.Helfat, C. E., & Winter, S. G. (2011). Untangling dynamic and operational capabilities: Strategy for the (N) ever-changing world. *Strategic management journal*, 32 (11), pp. 1243-1250.
- 136.Henderson, R. M., & Clark, K. B. (1990). Architectural innovation: The reconfiguration of existing product technologies and the failure of established firms. *Administrative science quarterly*, pp. 9-30.
- 137.Herstatt, C., Verwon, B., & Nagahira, A., (2004), Reducing project related uncertainty in the “fuzzy front end” of innovation: a comparison of German and Japanese product innovation projects, *International Journal of Product Development*, 1 (1), pp. 45-63.
- 138.Hervas-Oliver, J. L., Garrigos, J. A., & Gil-Pechuan, I. (2011). Making sense of innovation by R&D and non-R&D innovators in low technology contexts: A forgotten lesson for policymakers. *Technovation*, 31(9), pp. 427-446.
- 139.Higgins, J. M. (1996). Innovate or evaporate: creative techniques for strategists. *Long Range Planning*, 29 (3), pp. 370-380.

140. Hirsch-Kreinsen, H., & Bender, G. (2006). Policy and Innovation in Low-Tech - Knowledge Formation, Employment & Growth Contributions of the 'Old Economy' Industries in Europe. PILOT, Final report, DG Research, European Commission.
141. Hirsch-Kreinsen, H. (2008). 'Low-Tech' innovations. *Industry and Innovation*, 15 (1), p. 19–43.
142. Hirsch-Kreinsen, H., & Schwinge, I. (2011). Knowledge-intensive entrepreneurship and innovativeness in traditional industries: Conceptual framework and empirical findings, AEGIS project deliverable 1.3.1.
143. Hirsch-Kreinsen, H. (2015). Innovation in low-tech industries: current conditions and future prospects. In *Low-tech innovation* (pp. 17-32). Springer International Publishing.
144. Hitt, M., & Ireland, D. (1985). Corporate distinctive competence, strategy, industry and performance. *Strategic Management Journal*, 6 (3), pp. 273-293.
145. Hoffman, K., Parejo, M., Bessant, J., & Perren, L. (1998). Small firms, R&D, technology and innovation in the UK: a literature review. *Technovation*, 18 (1), pp. 39–55
146. Howard W.G., & Guile B.R. (1992). *Profiting from Innovation*. The Free Press.
147. Hollanders, H., & ter Weel, B. (2002). Technology, knowledge spillovers and changes in employment structure: evidence from six OECD countries, *Labour Economics*, 9, pp. 579–599.
148. Hull, R., Coombs, R., & Peltu, M. (2000). Knowledge management practices for innovation: an audit tool for improvement. *International Journal of Technology Management*, 20, pp. 633–656.
149. Hult, G. T. M., Hurley, R. F., & Knight, G. A. (2004). Innovativeness: Its antecedents and impact on business performance, *Industrial Marketing Management*, 33 (5), pp. 429–438.

150. Hunter, S. T., Bedell, K. E., & Mumford, M. D. (2007). Climate for creativity: A quantitative review. *Creativity Research Journal*, 19, pp. 69–90.
151. Hurley, R. F., & Hult, T. M. (1998). Innovation, market orientation, and organizational learning: An integration and empirical examination. *Journal of Marketing*, 62, pp. 42-54.
152. Hurley, R., Hult, G., & Knight, G., (2005). Innovativeness and capacity to innovate in a complexity of firm-level relationships: a response to Woodside, *Industrial Marketing Management*, 34 (3), pp. 281-283.
153. Huybers, T., Bennett, J. (2000). Impact of the environment on holiday destination choices of prospective UK tourists: implications for Tropical North Queensland, *Tourism Economics*, 6 (1), pp. 21-46.
154. Makri, M., & Scandura, T. A. (2010). Exploring the effects of creative CEO leadership on innovation in high-technology firms. *The Leadership Quarterly*, 21, pp. 75–88.
155. MINGO (2014). Industrijska strategija Republike Hrvatske 2014. – 2020, Sažetak, Republika Hrvatska. Dostupno na: http://www.privredni.hr/images/dokumenti/PV-Industrijska_strategija_RH_2014-2020-sazetak-1_14.pdf. [Pristup 12.2. 2016.].
156. Jacob, M., Tintore, J., Simonet, R., & Aguilo, E. (2004). Pautas de Innovacion en el Sector Turistico Balear. Estudio No. 25 de Fundacion COTEC, Madrid.
157. Jacobs, D., & Snijders, H. (2008). *Innovation routine: how managers can support repeated innovation*. Stichting Management Studies.
158. Jaegers, T., Lipp-Lingua, C., & Amil, D. (2013). High-technology and medium-high technology industries main drivers of EU-27's industrial growth. Dostupno na: <http://ec.europa.eu/eurostat/documents/3433488/5585612/KS-SF-13-001-EN.PDF/f68ec994-79d3-43f2-a7a9-787b73fdfe7e>. [pristup 16 .3. 2017.]
159. Jung, D., Wu, A., & Chow, C. W. (2008). Towards understanding the direct and indirect effects of CEO's transformational leadership on firm innovation. *The Leadership Quarterly*, 19, pp. 582–594.

160. Kamal M.M. (2006). IT Innovation Adoption in the Government Sector: Identifying the Critical Success Factors. *Journal of Enterprise Information Management*, 19 (2), pp. 192–222.
161. Kaplan, R. S., & Norton, D. P. (1992). The balanced scorecard – measures that drive performance. *Harvard Business Review*, January–February, pp. 71–79.
162. Kemp, R., & Pearson, P. (2007). Final report MEI project about measuring eco-innovation. *UM Merit, Maastricht*, 10.
163. Kesting, P., & Günzel-Jensen, F. (2015). SMEs and new ventures need business model sophistication. *Business Horizons*, 58 (3), pp. 285-293. doi: 10.1016/j.bushor.2015.01.002
164. Kaufmann, A., & Todtling, F. (2002). How effective is innovation support for SMEs? An analysis of the region of Upper Austria. *Technovation*, 22, pp. 147–159.
165. Kim, J. & Wilemon, D. (2002). Strategic issues in managing innovation's fuzzy front-end. *European Journal of Innovation Management*, 5, pp. 27–39.
166. Kimberly, J. R., & Evanisko, M., (1981). Organizational innovation: The influence of individual, organizational and contextual factors on hospital adoption of technological and administrative innovations. *Academy of Management Journal*, 24, pp. 689–713.
167. Kline S. J. & Rosenberg N. (1986). An overview of innovation. In: Landau R., Rosenberg N. (Eds). *The Positive Sum Strategy*. Washington, D.C.: National Academy Press, pp. 275– 305.
168. Knight K. (1967). A Descriptive Model of the Intra-Firm Innovation Process. *The Journal of Business*, 40 (4), pp. 478–496.
169. Knudsen E. S., & Lien L. B. (2014). Investments in Recessions. *Advances in Strategic Management*, 31, p. 3-36.
170. Koc, T., & Ceylan, C. (2007). Factors impacting the innovative capacity in large-scale companies. *Technovation*, 27, pp. 105-114.

171. Koen, P., Ajamian, G., Burkart, R., Clamen, A., Davidson, J., D'Amore, R., Elkins, C., Herald, K., Incorvia, M., Johnson, A., Karol, R., Seibert, R., Slavejkov, A. & Wagner, K. (2001). Providing clarity and a common language to the 'fuzzy front end'. *Research-Technology Management*, 44, pp. 46–55.
172. Kotabe, M., Srinivasan, S. S., & Aulakh, P. (2002). Multinationality and firm performance: The moderating role of R&D and Marketing Capabilities. *Journal of International Business Studies*, 33 (1), pp. 79-97.
173. Kotsemir, M., & Meissner, D. (2013). Conceptualizing the innovation process - Trends and outlook basic, *Basic research program working papers series: Science, Technology and Innovation*, WP BRP 10/STI/2013.
174. Kumbhakar, S. C., Ortega-Argilés, R., Potters, L., Vivarelli, M., & Voigt, P. (2012). Corporate R&D and firm efficiency: evidence from Europe's top R&D investors, *Journal of Productivity Analysis*, 37, pp. 125–140.
175. Lall, S. (1992). Technological capabilities and industrialization. *World Development*, 20 (2), pp. 165-186.
176. Laursen, K., & Salter, A. (2006). Open for innovation: the role of openness in explaining innovation performance among U.K. manufacturing firms. *Strategic Management Journal*, 27 (2), pp. 131–150.
177. Lawson, B. & Samson, D. (2001). Developing innovation capability in organisations: a dynamic capabilities approach. *International Journal of Innovation Management*, 5 (3): 377–400.
178. Leiponen, A., & Helfat, C. E. (2010). Innovation objectives, knowledge sources, and the benefits of breadth. *Strategic Management Journal*, 31(2), pp. 224-236.
179. Likar, B., Fatur, P., Ropret, M., Trček, D., Markič, M., Bavec, C., Škafar, M., & Rodman, K. (2011). *Referenčni model inoviranja: zaključno poročilo o rezultatih raziskovalnega projekta*. Koper: Fakulteta za management

- 180.Likar, B. (2013). *Innovation management*. Korona plus - Institute for Innovation and Technology.
- 181.Likar, B., Kopa, J., & Fatur, P. (2014) Innovation investment and economic performance in transition economies: Evidence from Slovenia. *Innovation: Management, Policy & Practice*, 16 (1), pp. 53–66.
- 182.Likar, B., Fatur, P., Ropret, M., Trček, D., Markič, M., Bavec, C., Škafar, M., & Rodman, K. (2014a). *O inovativnosti slovenske predelovalne in izbranih storitvenih dejavnosti*. Univerza na Primorskem, Fakulteta za management, Koper.
- 183.Lindgren, M. (2012). *21st Century Management: Leadership and Innovation in the Thought Economy*. Palgrave Macmillan.
- 184.LLorens-Montes, F. J., Garcia-Morales, V. J., & Verdu-Jover, A. J. (2004). The influence on personal mastery, organisational learning and performance of the level of innovation: adaptive organisation versus innovator organisation. *International Journal of Innovation and Learning*, 1 (2), pp. 101-114.
- 185.Love, J. H., & Roper, S. (1999). The Determinants of Innovation: R&D, Technology Transfer and Networking Effects. *Review of Industrial Organization*, 15, pp. 43-64.
- 186.Love, J. H., & Roper, S. (2002). Internal versus external R&D: a study of R&D choice with sample selection. *International Journal of the Economics of Business*, 9(2), pp. 239-255.
- 187.Love, J. H., & Roper, S. (2015). SME innovation, exporting and growth: A review of existing evidence. *International Small Business Journal*, 33 (1), pp. 28-48.
- 188.Lu, Q. (2000). *China's Leap into the Information Age: Innovation and Organization in the Computer Industry*. Oxford University Press, New York.
- 189.Luecke, R., & Katz, R. (2003). *Managing Creativity and Innovation*. Boston, MA: Harvard Business School Press. ISBN 1-59139-112-1.

190. Lyne, M. B. (2003). Aligning R&D with business strategy. *Research Technology Management*, 46 (6), pp. 44–46.
191. MacCallum, R. C., Widaman, K. F., Zhang, S. B., & Hong, S. H. (1999). Sample size in factor analysis. *Psychological Methods*, 4(1), pp. 84-99.
192. Margetta, J. (2002). What Management Is. *How it works and why it's everyone's business*.
193. Maidique M. (1980). Entrepreneurs, Champions, and Technological Innovation. *Sloan Management Review*, 21 (2), pp. 59–76.
194. Mann, L. (2005). *Leadership, management, and innovation in R&D project teams*. London: Praeger.
195. Martensen, A., Dahlgaard, J. J., Mi Park-Dahlgaard, S., & Grønholdt, L. (2007). Measuring and diagnosing innovation excellence—simple contra advanced approaches: a Danish study. *Measuring business excellence*, 11 (4), pp. 51-65.
196. Martin, B. R. (2012). Innovation studies: Challenging the boundaries. Sussex: *Science and Technology Policy Research*, University of Sussex
197. Martínez-Ros, E., & Labeaga, J. M. (2009). Product and process innovation: Persistence and complementarities. *European Management Review*, 6 (1), pp. 64-75.
198. Martinez-Ros, E., & Orfila-Sintes, F. (2009). Innovation activity in the hotel industry, *Technovation*, 29 (9), pp. 632-641.
199. Mensch, G., Kaash, K., Kleinknecht, A. & Schnapps, R. (1980). Innovation Trends and Switching between Full- and Under-employment Equilibrium, 1950-1978, *International Institute of Management*, Discussion Paper Series, Berlin, January.
200. Merrifield, B. D. (1986). Forces of Change Affecting High Technology Industries, A speech by U.S. Assistant Secretary of Commerce.

201. Michalisin, M. D. (2001). Validity of annual report assertions about innovativeness: an empirical investigation. *Journal of Business Research*, 53 (3), pp. 151-161.
202. Mion, G., & Zhu, L. (2013). Import competition from and offshoring to China: a curse or blessing for firms? *Journal of International Economics*, 89, pp. 202–215.
203. Moenaert, R.K., De Meyer, A., Souder, W.E. and Deschoolmeester, D. (1995). R&D/Marketing communication during the fuzzy front-end. *IEEE Transactions on Engineering Management*, 42, 243–257.
204. Montresor S., & Marzetti G.V. (2008). Innovation Clusters in Technological Systems: A Network Analysis of 15 OECD Countries for the Mid-1990s. *Industry and Innovation*, 15 (3), pp. 321–346.
205. Moore, T., & Mirzaei, A. (2016), The Impact of the Global Financial Crisis on Industry Growth. *The Manchester School*, 84, p. 159–180.
206. Morić Milovanović, B. (2009). Uloga menadžmenta u poticanju poduzetničkih aktivnosti velikih hrvatskih poduzeća. *Poslovna izvrsnost*, 3(1), str. 25-44.
207. Mulej, M., Likar, B., & Potočan, V. (2005). Increasing the Capacity of Companies to Absorb Inventions from Research Organizations and Encouraging People to Innovate. *Cybernetics and Systems*, 36, pp. 491-512.
208. Muresan, E., & Wolitzer, P. (2004). Organize your financial ratios analysis with PALMS (EMuresan Working paper No 02-01)
209. Myers S., Marquis D.G. (1969). Successful Industrial Innovations: A Study of Factors Underlying Innovation in Selected Firms, NSF 69-17, Washington: National Science Foundation.
210. Nahapiet, J., & Ghoshal, S. (1998). Social capital, intellectual capital, and the organizational advantage. *Academy of Management Review*, 23, pp. 242-266.

211. Nath, P., Nachiappan, S., & Ramanathan, R. (2010). The impact of marketing capability, operations capability and diversification strategy on performance: A resource-based view. *Industrial Marketing Management*, 39 (2), pp. 317–329
212. Nelly, A., Mills, J., Platts, K., Richards, H., Gregory, M., Bourne, M. & Kennerkley, M. (2000). Performance measurement system design: developing and testing a process-based approach. *International Journal of Operations and Production Management*, 20, pp. 1119-1145.
213. Nelson, R. R. (1993). *National Systems of Innovation: A Comparative Analysis*, Oxford: Oxford University Press.
214. Nelson, R., & Winter, S. (1982). *An Evolutionary Theory of Economic Change*. Cambridge, Ma.: The Belknap Press of Harvard University Press.
215. Niosi J. (1999). Fourth-Generation R&D: From Linear Models to Flexible Innovation. *Journal of Business Research*, Vol. 45(2), pp. 111–117.
216. Neely, A., & Bourne, M. (2000). Why measurement initiatives fail. *Measuring business excellence*, 4 (4), pp. 3-7.
217. Neely, A., Filippini, R., Fotza, C., Vinelli, A., & Hii, J. (2001). A framework for analysing business performance, firm innovation and related contextual factors: perceptions of managers and policy makers in two European regions. *Integrated Manufacturing Systems*, 12 (2), pp. 114-124.
218. Neely, A., Gregory, M., & Platts, K. (2005). Performance measurement system design: a literature review and research agenda. *International Journal of Operations & Production Management*, 25 (12), pp. 1228-1263.
219. Nobelius, D. (2004). Towards the sixth generation of R&D management. *International Journal of Project Management*, 22 (5), pp. 369–375.
220. Nonaka, L., & Takeuchi, H. (1995). *The knowledge creating company: How Japanese companies create the dynamics of innovation*. New York: Oxford Press.

221. Norman, G. (2010). Likert scales, levels of measurement and the “laws” of statistics. *Advances in Health Science Education*, 5(5) pp. 625-632.
222. Nybakk, E., & Jenssen, J. I. (2012). Innovation strategy, working climate, and financial performance in traditional manufacturing firms: An empirical analysis. *International Journal of Innovation Management*, 16 (2), pp. 1–26.
223. O’Connor, G.C., McDermott, C.M. (2004). The human side of radical innovation. *Journal of Engineering and Technology Management*, 21 (1–2), pp. 11–30.
224. OECD (2005). *Oslo Manual: Guidelines for Collecting and Interpreting Innovation Data*, OECD, Paris.
225. OECD (2009). *OECD Science, Technology and Industry Scoreboard. Main Science and Technology Indicators Database*. June 2009.
226. OECD (2011). *Science, Technology and Industry Scoreboard 2011*. OECD
227. Ogawa, K., & Tanaka, T. (2013). The global financial crisis and small- and medium-sized enterprises in Japan: how did they cope with the crisis? *Small Business Economics*, 41, pp. 401–417.
228. Oke, A., Walumbwa, F.O., & Myers, A. (2012). Innovation strategy, human resource policy, and firms’ revenue growth: The roles of environmental uncertainty and innovation performance. *Decision Sciences*, 43 (2), pp. 273–302.
229. Onetti, A., Zucchella, A., Jones, M. V., & McDougall-Covin, P. P. (2012). Internationalization, innovation and entrepreneurship: business models for new technology-based firms. *Journal of Management & Governance*, 16 (3), pp. 337-368.
230. Orfila-Sintes, F., Crespi-Cladera, R., & Martinez-Ros, E. (2005). Innovation activity in the hotel industry: evidence from Balearic Islands. *Tourism Management*, 26, (6), pp. 851-865.

- 231.Orfila-Sintes, F., & Mattsson, J. (2009). Innovation behavior in the hotel industry, *Omega*, 37 (2), pp. 380-394.
- 232.Otley, D. (2007). Accounting performance measurement: a review of its purposes and practices, pp. 11-35. u knjizi Neely. A., *Business Performance Measurement-Ubifying Theory and Integrated Practices*, Cambridge University Press.
- 233.Østergaard, C. R., Kristinsson, K., & Timmermans, B. (2008, Svibanj). Does Employee Diversity Lead to Innovation? U *25th Druid Celebration Conference: Entrepreneurship and Innovation: Organizations, Institutions, Systems and Regions*.
- 234.Palmberg, C. (2001). Sectoral patterns of innovation and competence requirements. *Sita Report Series No.8*, Helsinki
- 235.Parthasarthy, R., & Hammond, J. (2002). Product innovation input and outcome: moderating effects of the innovation process. *Journal of engineering and technology management*, 19 (1), pp. 75-91.
- 236.Pavie, X., Hsu, E., Rödle, H. J. T., & Tapia, R. O. (2013). How to Define and Analyze Business Model Innovation in Service. ESSEC Working Paper No. 1323. Available at SSRN: <https://ssrn.com/abstract=2370384>.
- 237.Pavitt, K. (1984). Sectoral patterns of technical change: towards a taxonomy and a theory. *Research Policy*, 13, pp. 343–373.
- 238.Pisano, G. P., & Shih, W. C. (2009). Restoring American competitiveness. *Harvard Business Review*, 87, pp. 114–125.
- 239.Pellens, M., Peters, B., Rammer, C., & Licht, G. (2016). *Public investment in R&D in relation to economic crises—A longitudinal study for OECD countries* (No. 16). SPINTAN Working papers Series.
- 240.Penrose, E., (1959). *The Theory of the Growth of the Firm*. Oxford University Press, New York.

241. Perić, M., & Vitezić, V. (2016). Impact of global economic crisis on firm growth. *Small Business Economics*, 46 (1), pp. 1-12.
242. Peters, B., & Rammer, C. (2013). Innovation Panel Surveys in Germany, in: Gault, F., Handbook of Innovation Indicators and Measurement, Cheltenham, UK and Northampton, MA, USA., pp. 135-177.
243. Peng, D. X., Schroeder, R. G., & Shah, R. (2007). Linking routines to operations capabilities: A new perspective. *Journal of Operations Management*, 26 (6), pp. 730-748.
244. Piening, E. P., & Salge, T. O. (2015). Understanding the antecedents, contingencies, and performance implications of process innovation: A dynamic capabilities perspective. *Journal of Product Innovation Management*, 32 (1), pp 80-97.
245. Popović, Ž., & Vitezić, N. (2000). *Revizija i analiza: instrumenti uspješnog donošenja poslovnih odluka*. Hrvatska zajednica računovođa i financijskih djelatnika.
246. Porter, M. E. (1980). *Competitive strategy: Techniques for analyzing industries and competitors*. New York: Free Press.
247. Porter, M.E. (1988). *Competitive Advantage: Creating and Sustaining Superior Performance*, Free Press.
248. Prahalad, C. K., & Hamel, G. (1990). The core competence of the corporation. *Harvard Business Review*, 68 (3), pp. 79-91.
249. Pratali, P. (2003). Strategic management of technological innovations in the small to medium enterprise. *European Journal of Innovation Management*, 6 (1), pp. 18–31.
250. Prašnikar, J. (2006). *Competitiveness, social responsibility and economic growth*. Nova Science Publ., New York
251. Protogerou A., Caloghirou, Y., & Karagouni, G. (2013). The relevance of the dynamic capabilities perspective in low-tech sectors, in Knowledge-Intensive Entrepreneurship in

Low-Tech Sectors: The Prospects of Traditional Economic Industries, H. Hirsch-Kreinsen and I. Schwinge (eds.), Edward Elgar Publishing, UK.

252. Pulic, A. (1998). Measuring the performance of intellectual potential in a knowledge economy, paper presented at 2nd McMaster World Congress. Dostupno na: www.vaicon.net [pristup 16 .2. 2015.]
253. Pulic, A. (2004). Intellectual capital-does it create or destroy value? *Measuring Business Excellence*, 8 (1), pp. 62-68.
254. Račić, D., Radas S., & Rajh D. (2005). *Innovation in Croatian enterprises: preliminary findings from community innovation survey*, Proceedings of the 65th Anniversary Conference of the Institute of Economics, Zagreb, Zagreb: Ekonomski institut, Zagreb, 403- 427.
255. Rammer, C. (2002). Innovationsverhalten der Unternehmen, Studien zum deutschen Innovationssystem Nr. 12-2003, ZEW, Mannheim.
256. Rammer, C., Czarnitzki, D., & Spielkamp, A. (2009). Innovation success of non-R&D-performers: substituting technology by management in SMEs. *Small Business Economics*, 33 (1), pp. 35-58.
257. Raspor, S. (2012). *Multivarijatna statistička analiza zadovoljstva klijenta u hotelskoj industriji*, doktorska disertacija. Sveučilište u Rijeci, Fakultet za menadžment u turizmu i ugostiteljstvu, Opatija.
258. Rau, S. E., & Bye, B. S. (2003). Are you getting value from your IT? *Journal of Business Strategy*, 24 (3), pp. 16-20.
259. Riahi-Belkaoui, A. (2003). Intellectual capital and firm performance of US multinational firms. *Journal of Intellectual Capital*, 4 (2), pp. 215-226.
260. Richardson, G. (1972). The organization of industry. *Economic Journal*, 82 (327), pp. 883-896.

261. Rosenberg, N. (1982). *Inside the Black Box: Technology and Economics*. New York: Cambridge University Press.
262. Rothwell, R. Z. (1985). *Reindustrialization and Technology*. Harlow, U.K.: Longman.
263. Roberts, E.B., (1998), Managing invention and innovation. *Research-Technological Management*, 31 (1), pp.11-27.
264. Rothwell, R., (1994). Towards the Fifth-generation Innovation Process. *International Marketing Review*, 11 (1), pp. 7-31
265. Rogers E. M. (1995). *Diffusion of innovations*. New York: Free Press, 4th edition.
266. Saunila, M., Ukko, J. (2011). A conceptual framework for the measurement of innovation capability and its effects, *Baltic Journal of Management*, 7(4), pp. 355-375.
267. Schultz, T. W. (1961). Investment in human capital. *American Economic Review*, 51, pp. 1-17.
268. Schumpeter, J. A. (1934). *Theory of Economic Development*. Harvard University Press, Cambridge, MA.
269. Schumpeter, J. A. (1939). *Business cycles: a Theoretical, Historical, and Statistical Analysis of the Capitalist Process*, New York: McGraw Hill.
270. Schumpeter, J. A. (1942). *Capitalism, Socialism, and Democracy*. Harper, New York
271. Selznick, P. (1957). *Leadership in administration: a sociological interpretation*. University of California Press, Berkeley and Los Angeles, Ca.
272. Sethibe, T., & Steyn, R. (2016). Innovation and organisational performance: A critical review of the instruments used to measure organisational performance, *The Southern African Journal of Entrepreneurship and Small Business Management*, 8 (1), pp. 1015-3977.

273. Sheather, G. (2002). Transforming Australian manufacturing enterprises for global competitiveness. *International Journal of Technology Management*, 24 (5-6), pp. 514–527.
274. Skinner, W., (1969). Manufacturing – missing link in corporate strategy. *Harvard Business Review*, 47 (3), pp. 136–145.
275. Slater, S. F., Olson, E. M., & Finnegan, C. (2011). Business strategy, marketing organization culture, and performance. *Marketing Letters*, 22 (3), pp. 227-242.
276. Slater, S. F., Mohr, J. J., & Sengupta, S. (2014). Radical product innovation capability: Literature review, synthesis, and illustrative research propositions. *Journal of Product Innovation Management*, 31 (3), pp. 552-566.
277. Som, O., & Kirner, E. (Eds.). (2014). *Low-tech Innovation: Competitiveness of the German Manufacturing Sector*. Springer.
278. Song, M., Droge, C., Hanvanich, S., & Calantone, R. (2005). Marketing and technology resource complementarity: an analysis of their interaction effect in two environmental contexts. *Strategic Management Journal*, 26 (3), pp. 259–276.
279. Song, M., Benedetto, C. A., & Nason, R. W. (2007). Capabilities and financial performance: the moderating effect of strategic type. *Journal of the Academy of Marketing Science*, 35 (1), pp. 18–34.
280. Souto, J. E. (2015). Business model innovation and business concept innovation as the context of incremental innovation and radical innovation. *Tourism Management*, 51, pp. 142-155.
281. Stevens, G. A., & Burley, J. (1997). 3,000 raw ideas = 1 commercial success! *Research-Technology Management*, May-June, pp. 16-27.
282. Subramaniam, M., & Youndt, M. A. (2005). The influence of intellectual capital on the types of innovative capabilities. *Academy of Management journal*, 48 (3), pp. 450-463.

283. Sullivan, P. H. (1999). Profiting from intellectual capital. *Journal of Knowledge Management*, 3 (2), pp. 132-142.
284. Swink, M., Hegarty, W.H. (1998). Core manufacturing capabilities and their links to product differentiation. *International Journal of Operations and Production Management*, 18 (3-4), pp.374-396.
285. Szirmai, A. (2012). Industrialisation as an engine of growth in developing countries 1950-2005. *Structural Change and Economic Dynamics*, 23, pp. 406-420.
286. Szirmai, A., & Verspagen, B. (2015). Manufacturing and economic growth in developing countries, 1950-2005. *Structural Change and Economic Dynamics*, 34, pp. 46-59.
287. Teece, D. J., Pisano, G., & Shuen, A. (1997). Dynamic capabilities and strategic management. *Strategic Management Journal*, 18 (7), pp. 509-533.
288. Teece, D. J. (2007). Explicating dynamic capabilities: The nature and microfoundations of (sustainable) enterprise performance. *Strategic Management Journal*, 28 (13), pp. 1319-1350.
289. Teece, D. J. (2009). *Dynamic capabilities and strategic management: Organizing for innovation and growth*. Oxford University Press.
290. Teece, D. J. (2010). Business models, business strategy and innovation. *Long range planning*, 43 (2), pp. 172-194.
291. Terjesen, S., Patel, P. C., & Covin, J. G. (2011). Alliance diversity, environmental context and the value of manufacturing capabilities among new high technology ventures. *Journal of Operations Management*, 29 (1-2), pp.105-115.
292. Tintor, J. (2009). *Poslovna analiza*. Masmedia, Zagreb.
293. Tipurić D., Veža I., & Prester J. (2007.), Innovation in transition countries: how to catch up?, 14th EUROMA Conference, Ankara, Turkey, 17-20.06.2007.

294. Tsai, W. (2001). Knowledge transfer in intraorganizational networks: Effects of network position and absorptive capacity on business unit innovation and performance. *Academy of management journal*, 44 (5), pp. 996-1004.
295. Tunzelmann, von N., & Acha, V. (2005). Innovation in Low-Tech Industries. In: Faberberg, J., Mowery, D.C., Nelson, R.R. (urd.), *The Oxford Handbook of Innovation*, Oxford, pp. 407- 432.
296. Tura, T., Harmaakorpi, V. and Pekkola, S. (2008). Breaking inside the black box: towards a dynamic evaluation framework of regional innovative capability, *Science and Public Policy*, 35 (10), pp. 733-744.
297. Twiss, B. (1986). *Managing Technological Innovation*. London, Pitman.
298. UNWCED (1987). *Brundtland Report - World Commission on Environment and Development*.
299. UNU-MERIT (2013). *Innovation Union Scoreboard 2013*. Maastricht Economic and social Research Institute on Innovation and Technology
300. Usher A.P. (1954). *A History of Mechanical Inventions*. Revised edition. New York: McGraw Hill.
301. Usher A.P. (1955). *Technical Change and Capital Formation, in National Bureau of Economic Research, Capital Formation and Economic Growth*. Princeton: Princeton University Press, pp. 523-550.
302. Utterback, J. (1982). Environmental analysis and forecasting. *Readings in the Management of Innovation*. Drugo izdanje, Tushman, M., L. i Moore, W., L. (ured.). Harper Business, pp. 299-310.
303. Varra, L., Buzzigoli, C., & Loro, R. (2012). Innovation in Destination Management: Social Dialogue, Knowledge Management Processes and Servant Leadership in the Tourism Destination Observatories”, *Procedia – Social and Behavioral Sciences*, 41, pp. 375-385.

304. Verloop, J. (2004). *Insight in Innovation: Managing innovation by understanding the Laws of Innovation*. Elsevier Science.
305. Verworn, B. (2002). The fuzzy front end of product development: an exploratory study. In Proceedings, 9th International Product Development Management Conference, Sophia Antipolis, France, pp. 863–878. Brussels: European Institute for Advanced Studies in Management.
306. Veža, I., & Prester, J. (2008). Innovation in Croatian manufacturing 2004: What do financial results show? *Economic and business review : for Central and South-Eastern Europe* (1580-0466) 10, pp. 5-19.
307. Vickery, S. K., Droge, C., Markland, R. E. (1993). Production competence and business strategy: Do they affect business performance? *Decision Sciences*, 24 (2), pp. 435–455.
308. Vitezic, N., & Vitezic, V. (2015). A conceptual model of linkage between innovation management and controlling in the sustainable environment. *Journal of Applied Business Research*, 31 (1), pp. 175-184.
309. Vitezić, V., Car, T., & Šimunić, M. (2015). Managing Innovative Technology in the Hotel Industry-Response to Growing Consumer Preferences. *Tourism in Southern and Eastern Europe*, 3, pp. 467-478.
310. Von Hippel, E., & Schrader, S. (1996). Managed informal information trading: the oil scout system in oil exploration firms. *International Journal of Technology Management*, 11 (1/2), pp. 207–218.
311. Wheelwright, S. C., & Clark, K. B. (1992). *Revolutionizing Product Development*. New York, The Free Press.
312. Williams, A. M., & Shaw, G. (2011). Internationalization and innovation in tourism. *Annals of Tourism Research*, 38 (1), pp. 27-51.
313. Wirtz, B. W., Pistoia, A., Ullrich, S., & Göttel, V. (2016). Business models: Origin, development and future research perspectives. *Long Range Planning*, 49 (1), pp. 36-54.

314. World Economic Forum (2012). *The Global Competitiveness Report 2012–2013*. Geneve: World Economic Forum.
315. West, M. A. (1990). The social psychology of innovation in groups. In West, M.A. and Farr, J.L. (eds), *Innovation and Creativity at Work: Psychological and Organizational Strategies*. Chichester, UK: John Wiley, pp. 309–333.
316. West, M. A., Borril, C. S., Dawson, J. F., Brodbeck, F., Shapiro, D. A., & Haward, B. (2003). Leadership clarity and team innovation in health care. *The Leadership Quarterly*, 14, pp. 393–410.
317. Yliherva, J. (2004). Management model of an organisation's innovation capabilities – development of innovation capabilities as part of the management system, dissertation, Department of Industrial Engineering and Management, University of Oulu, Oulu
318. Yen, Y., (2013). The impact of bank's human capital on organizational performance: How innovation influences performance', *Innovation: Management, Policy & Practice*, 15 (1), pp. 112–128.
319. Youndt, M. A., Subramaniam, M., & Snell, S. A. (2004). Intellectual capital profiles: An examination of investments and returns. *Journal of Management Studies*, 41 (2), pp. 335-362.
320. Zahra, S., Sapienza, H. J., & Davidsson, P. (2006). Entrepreneurship and Dynamic Capabilities: A Review, Model and Research Agenda. *Journal of Management Studies*, 43 (4), pp. 917–955.
321. Zott, C., & Amit, R. (2007). Business model design and the performance of entrepreneurial firms. *Organization science*, 18 (2), pp. 181-199.
322. Zott, C., Amit, R., & Massa, L. (2010). The business model: Theoretical roots, recent developments, and future research. *IESE business school-University of Navarra*, pp. 1-43.

Web stranice

1. Australian Academy of Technology, Sciences and Engineering, <http://digbig.com/4wxmw>, 18.03.2014.
2. Hrvatska gospodarska komora, Republika Hrvatska 2016, <https://www.hgk.hr/documents/republikahrvatska2016hrweb5824783267fa1.pdf>,
3. Državni zavod za statistiku, Proizvodnja i prodaja industrijskih proizvoda (PRODCOM) u 2015., https://www.dzs.hr/Hrv_Eng/publication/2016/02-01-05_01_2016.htm, 22.6.2017.
4. Državni zavod za statistiku, Kalkulator inflacije, <https://www.dzs.hr/app/rss/stopa-inflacije.html>, 18.5.2017.
5. HORIZON 2020, The EU Framework Programme for Research and Innovation, www.ec.europa.eu, 29.5.2016.
6. Ministarstvo gospodarstva, poduzetništva i obrta, www.mingo.hr, 6.10.2016.
7. Organisation for Economic Co-operation and Development - OECD, www.oecd.org/germany/Better-policies-germany.pdf, 15.6.2015.
8. United Nations - Report of the World Summit on Sustainable Development, http://www.unmillenniumproject.org/documents/131302_wssd_report_reissued.pdf, 23.4.2015.

POPIS TABLICA

| | |
|---|-----|
| Tablica 1: Razvoj inovacijskih modela | 33 |
| Tablica 2: Faze inovacijskog procesa | 38 |
| Tablica 3: Tipične aktivnosti u inovacijskom procesu | 40 |
| Tablica 4: Razvoj inovacijske metrike kroz generacije | 42 |
| Tablica 5: Proizvodno-tehnološki pokazatelji | 48 |
| Tablica 6: Financijsko-tržišni pokazatelji | 49 |
| Tablica 7: Subjektivni pokazatelji | 50 |
| Tablica 8: Mjerenje područja inovacijskog menadžmenta | 51 |
| Tablica 9: Uzorak HR NTP | 90 |
| Tablica 10: Mann-Whitneyjev test o visini inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP | 94 |
| Tablica 11: Mann-Whitneyjev test o visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP | 95 |
| Tablica 12: Mann-Whitneyjev test o produktivnost inovacijskog procesa HR NTP | 97 |
| Tablica 13: Dodana vrijednost i prihod po skupinama HR NTP | 99 |
| Tablica 14: Profitabilnost i ekonomičnost inovacijskih skupina HR NTP | 100 |
| Tablica 15: Uzorak DE NTP | 105 |
| Tablica 16: Mann-Whitneyjev test o produktivnosti inovacijskog procesa DE NTP | 110 |
| Tablica 17: Udio ulaganja u R&D DE NTP | 111 |
| Tablica 18: Mann-Whitneyjev test o visini i strukturi ulaganja inovacijsko vodećih i neinovativnih DE NTP | 113 |
| Tablica 19: Mann-Whitneyjev test o visini i strukturi ulaganja inovacijsko vodećih i inovacijskih sljedbenika DE NTP | 114 |
| Tablica 20: Mann-Whitneyjev test o zaposlenima na poslovima R&D-ja DE NTP | 116 |
| Tablica 21: Mann-Whitneyjev test o inovacijskim sposobnostima inovacijsko vodećih i inovacijskih sljedbenika DE NTP | 118 |
| Tablica 22: Mann-Whitneyjev test o inovacijskim sposobnostima inovacijsko vodećih i neinovativnih DE NTP | 119 |
| Tablica 23: Mann-Whitneyjev test o prosječnim uštedama troškova DE NTP | 120 |

| | |
|--|-----|
| Tablica 24: Mann-Whitneyjev test o poboljšanjima u kvaliteti DE NTP..... | 122 |
| Tablica 25: Sažetak testiranja pomoćnih hipoteza primjenom Mann-Whitneyjeva testa..... | 123 |
| Tablica 26: Korelacije između ulaznih i procesnih čimbenika DE NTP | 124 |
| Tablica 27: Financijski pokazatelji inovacijskih skupina DE NTP | 126 |
| Tablica 28: Profitna marža inovacijskih skupina DE NTP..... | 127 |
| Tablica 29: Mann-Whitneyjev test o financijskoj efikasnosti inovacijsko vodećih i neinovativnih DE NTP | 128 |
| Tablica 30: Mann-Whitneyjev test o financijskoj efikasnosti inovacijsko vodećih i inovacijskih sljedbenika DE NTP | 129 |
| Tablica 31: Uzorak HR NTP 2015 | 134 |
| Tablica 32: Mann-Whitneyjev test o visini inovacijskih ulaganja inovacijsko vodećih i neinovativnih HR NTP 2015 | 139 |
| Tablica 33: Mann-Whitneyjev test o visini inovacijskih ulaganja inovacijsko vodećih i inovacijskih sljedbenika HR NTP 2015 | 140 |
| Tablica 34: Mann-Whitneyjev test zaposlenika uključenih na poslove R&D-ja HR NTP 2015 | 144 |
| Tablica 35: Sažetak testiranja pomoćnih hipoteza | 145 |
| Tablica 36: Skupina pokazatelja inovacijskih sposobnosti | 151 |
| Tablica 37: Deskriptivna analiza inovacijskih sposobnosti poduzeća..... | 154 |
| Tablica 38: KMO mjera adekvatnosti uzorka i Bartlettov test sferičnosti | 157 |
| Tablica 39: Odnos ispitanika i čestica u faktorskoj analizi | 158 |
| Tablica 40: Izlučeni faktori i varijanca..... | 159 |
| Tablica 41: Rezultati faktorske analize | 161 |
| Tablica 42: Prihvatljive vrijednosti Cronbach alpha koeficijenta | 165 |
| Tablica 43: Statistika čestica i pouzdanost unutar faktora <i>Organizacijska sposobnost</i> | 166 |
| Tablica 44: Statistika čestica i pouzdanost unutar faktora <i>Marketinška sposobnost</i> | 167 |
| Tablica 45: Statistika čestica i pouzdanost unutar faktora <i>Sposobnost strateškog upravljanja</i> | 168 |
| Tablica 46: Statistika čestica i pouzdanost unutar faktora <i>Proizvodna sposobnost</i> | 169 |
| Tablica 47: Statistika čestica i pouzdanost unutar faktora <i>Istraživačko-razvojna sposobnost</i> | 170 |

| | |
|--|-----|
| Tablica 48: Statistika čestica i pouzdanost unutar faktora <i>Informacijska i koordinacijska sposobnost</i> | 171 |
| Tablica 49: Korelacijska matrica faktora..... | 171 |
| Tablica 50: Mann-Whitneyjev test inovacijskih sposobnosti HR NTP 2015..... | 173 |
| Tablica 51: Mann-Whitneyjev test o prosječnim uštedama troškova HR NTP 2015 | 180 |
| Tablica 52: Mann-Whitneyjev test o poboljšanjima u kvaliteti HR NTP 2015 | 182 |
| Tablica 53: Financijski pokazatelji inovacijskih skupina HR NTP 2015 (u tisućama kn)..... | 192 |
| Tablica 54: Profitabilnost i ekonomičnost inovacijskih skupina HR NTP 2015..... | 193 |
| Tablica 55: Mann-Whitneyjev test o financijskoj efikasnosti inovacijsko vodećih i neinovativnih HR NTP 2015 | 195 |
| Tablica 56: Mann-Whitneyjev test o profitabilnosti i ekonomičnosti inovacijsko vodećih i neinovativnih HR NTP 2015 | 195 |
| Tablica 57: Rezultati testiranja hipoteza i utjecaji na model..... | 199 |

POPIS SLIKA

| | |
|--|-----|
| Slika 1: Podjela poduzeća na inovacijske skupine | 10 |
| Slika 2: Inovacije i održivost | 22 |
| Slika 3: Društveno odgovorno inoviranje..... | 23 |
| Slika 4: Henderson i Clark koncepti..... | 28 |
| Slika 5: Kompozitni inovacijski indeks..... | 55 |
| Slika 6: Trgovina zemalja OECD-a podijeljena po tehnološkoj intenzivnosti..... | 78 |
| Slika 7: Klasifikaciju proizvodnih ekonomskih aktivnosti..... | 84 |
| Slika 8: Podjela na inovacijske skupine | 89 |
| Slika 9: Model za prijelaz iz neinovativnog u inovativno vodeće poduzeće..... | 197 |

POPIS GRAFIKONA

| | |
|---|-----|
| Grafikon 1: Kompozitni pokazatelj inovacijskog učinka europskih zemalja..... | 81 |
| Grafikon 2: Struktura HR NTP u pogledu inovacijske aktivnosti..... | 91 |
| Grafikon 3: Visina i struktura ulaganja HR NTP u inovacijske aktivnosti | 92 |
| Grafikon 4: Produktivnost inovacijskog procesa HR NTP | 96 |
| Grafikon 5: Pozicija Njemačke prema kompozitnom pokazatelju inovacijskog učinka | 102 |
| Grafikon 6: Struktura DE NTP poduzeća u pogledu inovacijske aktivnosti | 106 |
| Grafikon 7: Struktura DE NTP poduzeća po djelatnostima | 107 |
| Grafikon 8: Produktivnost inovacijskog procesa DE NTP..... | 109 |
| Grafikon 9: Visina i struktura ulaganja DE NTP u inovacijske aktivnosti | 112 |
| Grafikon 10: Zaposlenici na poslovima R&D-ja DE NTP..... | 115 |
| Grafikon 11: Prihod i prihod po zaposlenom DE NTP | 125 |
| Grafikon 12: Struktura HR NTP 2015..... | 135 |
| Grafikon 13: Inovacija kao strateški prioritet..... | 136 |
| Grafikon 14: Visina i struktura ulaganja u inovacijske aktivnosti HR NTP 2015 | 137 |
| Grafikon 15: Usporedba visine ulaganja NTP u inovacijske aktivnosti..... | 141 |
| Grafikon 16: Usporedba visine ulaganja NTP u R&D..... | 142 |
| Grafikon 17: Zaposlenici na poslovima R&D-ja HR NTP 2015..... | 143 |
| Grafikon 18: Postotak visokoobrazovanih zaposlenika HR NTP 2015 | 146 |
| Grafikon 19: Troškovi za stručno usavršavanje HR NTP 2015 | 147 |
| Grafikon 20: Produktivnost inovacijskog procesa HR NTP 2015 | 148 |
| Grafikon 21: Investicije u inovacije u sljedećoj godini | 149 |
| Grafikon 22: Scree test | 160 |
| Grafikon 23: Inovacije procesa HR NTP 2015 | 177 |
| Grafikon 24: Prosječne uštede troškova potaknute inovacijama procesa..... | 179 |
| Grafikon 25: Povećanje prihoda kao rezultat poboljšanja u kvaliteti..... | 181 |

| | |
|---|-----|
| Grafikon 26: Organizacijske inovacije HR NTP 2015 | 184 |
| Grafikon 27: Inovacija poslovnih modela HR NTP 2015 | 185 |
| Grafikon 28: Marketinške inovacije HR NTP 2015 | 187 |
| Grafikon 29: Inovacijske prepreke | 188 |
| Grafikon 30: Mjerenje uspješnosti inovacije | 190 |