

## STANJE ISTRAŽIVANJA O UPRAVLJANJU ZNANJEM U PODRUČJU DIZAJNA

### STATE OF THE ART RESEARCH IN KNOWLEDGE MANAGEMENT IN THE FIELD OF DESIGN

Petra Močibov<sup>1</sup>, Nenad Bojčetić<sup>1</sup>

<sup>1</sup>Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu

#### Sažetak

U ovom radu dan je pregled trenutnog stanja istraživanja na području upravljanja znanjem, temeljen na člancima s ključnom riječju “*upravljanje znanjem*” (eng. “*knowledge management*”) sa konferencije o dizajnu (DESIGN 2014). Najprije se navode ključne prepreke upravljanju znanjem kojih je nužno biti svjestan kod uvođenja sustava upravljanja znanjem u tvrtke. Prepreke utječu i na odabir modela mape znanja tvrtke koji će se koristiti pri implementaciji. Opisana je metodologija za sustavno unapređenje znanja tvrtke kroz definiranje ciljeva, kreiranje mapa postojećeg i željenog znanja te odabir mjera za napredovanje od postojećeg do željenog stanja. Objašnjena jedna od mogućih metoda evaluacije znanja tvrtke, te je dan prikaz načina prijenosa znanja, tj. komunikacije među suradnicima na projektu koji se odvija u globalnim okolnostima.

**Ključne riječi:** *upravljanje znanjem, mapa znanja, sustavno unapređenje znanja, matrica kompetencija, prijenos znanja*

#### Abstract

This paper gives an overview of the state of the art research in the field of knowledge management, based on the articles with the key word “*knowledge management*” at the conference on design (DESIGN 2014). First, it illustrates key obstacles to knowledge management which is necessary to be aware of when implementing knowledge management systems in companies. Obstacles affect the selection of the knowledge map model of the company that will be used during implementation. The methodology for

the systematic improvement of knowledge of the company through defining goals, creating a map of the existing and desired knowledge and choice of measures for the advancement of the current to the desired state is described. One of the possible methods of evaluation of knowledge of the company is presented including the overview of the modes of transmission of knowledge, i.e. communication among co – workers on a project that takes place in a global setting.

**Keywords:** *knowledge management, knowledge map model, systematic improvement, competency matrix, transmission of knowledge*

#### 1. Uvod

##### 1. Introduction

U modernom inženjerskom svijetu, zapisivanje znanja i upravljanje zapisanim jedno je od gorućih pitanja na koja istraživači pokušavaju pronaći odgovor. Budući da je područje ljudskog znanja prije svega neopipljivo, istraživanja se kreću u smjerovima razumijevanja procesa učenja i procesa primjene naučenog; pronalaženja rješenja za formaliziranje neopipljivog; zapisivanja formaliziranog; vizualizacije zapisanog; pokušaja ponovne upotrebe zabilježenog.

Korist od rezultata istraživanja moguće je primijeniti na mnogo područja, osobito u inženjerstvu stoga su neka od navedenih pitanja neizbježna tema i na međunarodnoj konferenciji o konstruiranju. U ovom radu dan je pregled trenutnog stanja istraživanja na području upravljanja znanjem, temeljen na nekoliko članaka s ključnom riječju “*upravljanje znanjem*” (eng. “*knowledge management*”) objavljenih na spomenutoj konferenciji.

## 1.1 Ključne prepreke upravljanju znanjem

### 1.1 Key barriers to knowledge management

Kako bi implementacija nekog od modela bilježnja znanja bila uspješna potrebno je sagledati trenutno stanje stvari i utvrditi koji model najbolje odgovara radnom okruženju tvrtke u kojoj će se primjenjivati. Jedan od koraka sagledavanja konkretne situacije odnosi se na razumijevanje mogućih poteškoća koje se u tvrtki mogu pojaviti prilikom primjene određenog modela. Često je poteškoće teško uočiti unaprijed, no poznavanje problema koji su se javili u nekim od prethodnih pokušaja implementacije (u drugim tvrtkama) može pomoći u prevenciji problema. Vršitelji implementacije svakako bi trebali obratiti pažnju na moguće prepreke te pokušati prepreke zaobići kako odabirom čim prikladnijeg modela, tako i njegovom prilagodbom odgovarajućoj situaciji. Veliki dio prepreka predstavlja odnos korisnika prema sustavu, stoga su autori u [1], kroz trideset intervjua, ispitali inženjere iz područja razvoja proizvoda i područja osiguranja kvalitete, te članove višeg sloja upraviteljske hijerarhije (eng. “*senior – level management*”). Intervjui su provedeni u dvije tvrtke: (I) *Toyota Material Handling Europe (TMHE)* i (II) *Volvo Car Corporation (VCC)*. Sličnosti među tvrtkama navedene su u tablici (Tablica 1.). Autori članka namjerno izostavljaju razlike među tvrtkama kako bi ustanovili razlikuju li se, i kako, zahtjevi različitih industrijskih sektora na sustav upravljanja znanjem [1]. Međutim, autorica ovog rada smatra da je razumijevanje razlika barem jednako bitno koliko i razumijevanje sličnosti među tvrtkama s ciljem postavljanja što općenitijeg modela prepreka. Potonje je osobito važno ako bi se smjernice za implementaciju modela upravljanja znanjem razvile tako da je moguće razlikovati nekoliko osnovnih “paketa” problema ovisno o tipu tvrtke.

Analiza provedenih intervjua pokazala je sljedeće probleme [1]:

1. nedostatak vremena potrebnog za zapisivanje znanja (inženjeri su već ionako preopterećeni poslom)
2. nejasno je kada znanje treba potražiti u bazi znanja tvrtke (dio vrijednog znanja nesvjesno se gubi iz vida)

**Tablica 1** Karakteristike tvrtki u kojima je provedeno istraživanje [1]

**Table 1** Characteristics of the companies in which the research was carried out [1]

KARAKTERISTIKE	TMHE	VCC
Dio tržišta	Vrhunski/ količina	Vrhunski/ prilagodbeni
Odnos s klijentima	Kupac – kupac	Uglavnom kupac – klijent
Proizvedene jedinice	55 000	449 000
Udio na tržištu	Visok	Nizak
Promet (milijuni SEK)	4 000	107 000
Proizvodi	Platformski/mo- dularni	Platformski/ integrirani (modularna implementacija)
Industrijski sektor	Industrijska oprema	Automobilska industrija
Pogon	Mehanički/elek- trični	Mehanički/MSUI
Proizvodni proces	Poluautomatski	Visoki stupanj automatizacije
Broj zaposlenika	9 000	21 000

3. način pristupanja znanju (na koji način korisnici pristupaju podacima, primjerice kroz alate za pretraživanje baze znanja)
4. dostupnost znanja (svi zaposlenici nemaju jednaka dopuštenja po pitanju pristupa informacijama)
5. nestrukturiranost zapisa (poteškoće sa zapisivanjem znanja korištenjem teksta, dijagrama ili drugog slikovnog prikaza javljaju se osobito ako se zapisi ne vrše na materinjem jeziku ili se izmjenjuju među ljudima s različitim kulturnom pozadinom)
6. zapisi se ne obnavljaju (relevantnost zapisa postaje upitna)
7. nedostatak motivacije korisnika da koriste bazu znanja (korisnici ne vide korist u korištenju zapisanog znanja)
8. nedostatak rutine korisnika da stvaraju zapise znanja (upitno je što treba zapisati, kada i kako)
9. pojedinci zaboravljaju što su naučili (“Uvijek znamo više no što možemo reći, i uvijek kažemo više no što možemo zapisati.”)
10. poteškoće s održavanjem baze znanja

(primjerice, u postojećim PDM sustavima potrebno je načiniti mnogo akcija kako bi se neki zapis obnovio, osobito ako ga želi obnoviti osoba koja nije autor)

11. poteškoće s prijenosom znanja (primjerice prijenos znanja nekoj specifičnoj osobi nailazi na probleme slične onima koji uzrokuju nestrukturiranost zapisa)
12. poteškoće s dijeljenjem (kako prirediti zapise znanja tako da dijeljenje među više korisnika bude olakšano)

Sve navedene poteškoće intuitivno su jasne zbog same neopipljive prirode ljudskog znanja, ali i zbog ograničenosti informacijskih sustava koji su trenutno u upotrebi u tvrtkama. Dodatni problem koji se javlja je zamjena prirodne komunikacije među ljudima onom neprirodnom između čovjeka i stroja. Jedno od mogućih rješenja za unaprjeđenje komunikacije između čovjeka i stroja jest unaprjeđenje alata za pretragu baza znanja. Jedan od načina jest omogućiti pretraživanje postavljanjem konkretnih pitanja, a ne samo pretraga po, primjerice, ključnim riječima. Iz navedenog proizlazi da prije svega treba pronaći odgovarajući način zapisivanja znanja kako bi se iz zapisa mogla izvući maksimalna korist. To uključuje i definiranje modela zapisa znanja tako da zapis bude što jezgrovitiji, ali tako da prije svega prenosi potrebno znanje ili informaciju. Posljednje je bitno za održavanje baza podataka i omogućavanje brze pretrage i dostupnosti rezultata pretraživanja.

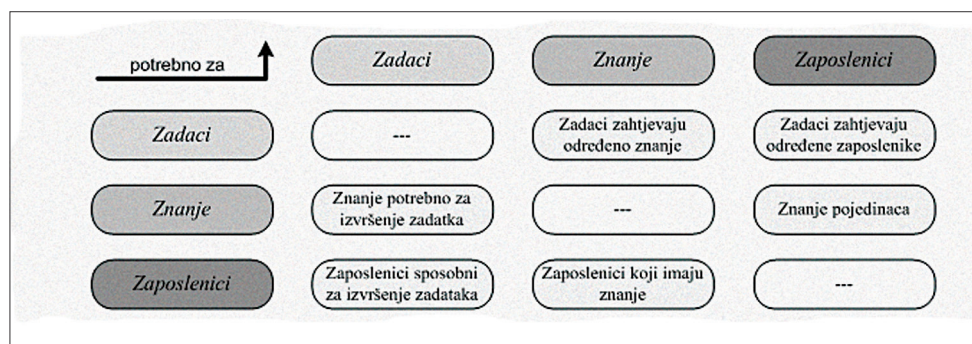
U nastavku je opisan jedan od modela zapisa znanja u vidu mape znanja. Bazirano na navedenom modelu, dane su neke metode za evaluaciju znanja tvrtke te način za unaprjeđenje istog u smjeru koji je od interesa za tvrtku. Dodatno, dan je osvrt na probleme vezane uz

prijenos i dijeljenje znanja (11 i 12) u vidu rada u globalnim timovima uz prisutnu kulturološku različitost te prostornu dislociranost među članovima tima.

## 1.2 Modeli zapisa znanja

### 1.2 Knowledge mapping models

Prema [2] i [3], struktura znanja može se opisati pomoću tri domene: (I) zadaci, (II) znanje i (III) zaposlenici. Relacije među domenama mogu se zapisati u vidu matrice (eng. “multiple domain matrix” – MDM) (Figure 1. [2] i Figure 2. [3]). U spomenutoj matrici koriste se sljedeće veze: (I) koje je znanje potrebno za izvršenje zadataka, tj. koji zadaci koji zahtijevaju određeno znanje; (II) zaposlenici izvršavaju zadatke i (III) zaposlenici imaju znanje, tj. znanje je dostupno od zaposlenika. Za prikupljanje podataka, tj. veza koje se u matricu mogu postaviti moguće je koristiti metodologiju prema [4]. Koristi od kreiranja mape znanja na način pokazan u [4] autorica ovog rada vidi u proširenu matricu prema [2] i [3] tako da se sve zabilježene veze unose u PLM/PDM sustav u kojem se tada mogu pratiti u oba smjera. U proširenoj matrici prikazanoj na slici (Slika 1.), polja matrice predstavljaju podmatrice koje sadrže imena zaposlenika, popise zadataka i prikupljeno znanje tvrtke. Unošenjem imena svih zaposlenika u PLM/PDM sustav te postavljanjem dvosmjernih veza zaposlenika sa zadacima i prikupljenim znanjem, kao i veza između znanja i zadataka olakšava se, primjerice, kreiranje novih timova kod sljedećih projekata. Dodatno unaprjeđenje sastoji se u evaluaciji kompetencija pojedinih zaposlenika čime se, prilikom kreiranja novih timova, između dvaju kandidata olakšava izbor. Dodatno, na temelju poznatih podataka, lako je odrediti konzultanta za projekt u slučaju da isti nije u mogućnosti na projektu sudjelovati u potpunosti.



**Slika 1**  
Matrična mapa znanja (prilagođeno prema [2,3])

**Figure 1**  
Matrix map of knowledge (adjusted according to [2,3])

## 2. Sustavno unaprjeđenje znanja

### 2. Systematic improvement of knowledge

Kako je već spomenuto, ako se znanje ne održava, ono se istovremeno nepovratno gubi. Kako do tog gubitka ne bi došlo, autori u [3] prikupili su iz literature 3 strategije, 40 mjera i 69 metoda za unaprjeđenje znanja. U danom kontekstu *mjere* opisuju kako realizirati strategiju, a *metode* predstavljaju smjernice za provođenje *mjera*.

### 2.1 Strategije, mjere i metode

#### 2.1 Strategies, measures and methods

Za unaprjeđenje znanja u tvrtki, autori pronalaze u pregledu literature sljedeće tri strategije [3]:

1. Stvaranje znanja  
Ova se strategija primjenjuje kada potrebno znanje u tvrtki još ne postoji. Neke od *mjera* su samo – učenje (eng. “*self – study*”), prijenos odgovornosti ili obuka za upravljanje projektima, a neke od *metoda* za spomenute *mjere* redom su provođenje tehnika kreativnosti, zapošljavanje novih radnika ili stručno osposobljavanje postojećih.
2. Dijeljenje znanja  
Odnosi se na dijeljenje znanja unutar tvrtke tako da zaposlenici koji do sada nisu bili upoznati s problemom mogu pristupiti znanju koje je prikupio netko drugi. Neke od *mjera* su organizacija pristupa znanju, ili učenje kroz podučavanje, a neke od *metoda* su osnivanje učilišta unutar tvrtke, kreiranje izvještaja o postojećim projektima ili slično.

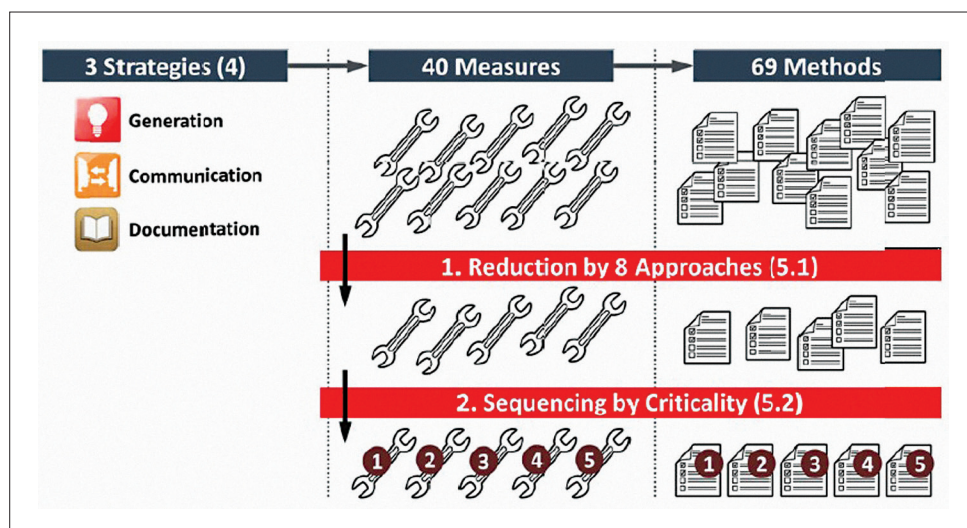
3. Dokumentiranje znanja  
Strategija dokumentiranja nužna je za čuvanje znanja unutar tvrtke, a ujedno omogućava i prijenos znanja izvan tvrtke u tvrtku. Neke od *mjera* su stvaranje projektne dokumentacije i upute o procesima, dok su *metode* zapisivanje prethodnih pogrešaka uz bilježenje mogućih poboljšanja ili kreiranje dokumenata koji sadrže upute o “dobraj praksi”.

### 2.2 Pristup

#### 2.2 Approach

Pristup sustavnom unaprjeđenju znanja provodi se kroz četiri faze [3]:

1. definiranje ciljeva i ograničenja (uključuje definiranje odgovornih zaposlenika za kreiranje mapa znanja te, primjerice, definiranje zaposlenika koji nemaju pristup konkretnom projektu)
2. kreiranje mape postojećeg znanja (eng. “*as – is knowledge map*”) (primjerice, na radionici se kreira za svakog zaposlenika individualna mapa znanja, a potom se, kombinacijom svih individualnih mapa, kreira mapa ukupnog postojećeg znanja tvrtke u danom trenutku)
3. kreiranje mape budućeg znanja (eng. “*to – be knowledge map*”) (nakon postavljanja željenog scenarija za tvrtku, mapa postojećeg znanja adaptira se u suradnji s menadžerima i vodećim zaposlenicima kako bi se otkrilo koje znanje treba nadograditi ili tek steći)
4. definiranje mjera za razvoj znanja od trenutne do željene situacije



**Slika 2**  
Koraci za sustavno unaprjeđenje znanja [3]

**Figure 2**  
Steps in systematic improvement of knowledge [3]

Budući da autori definiraju čak 40 mjera za daljnji razvoj znanja, razvili su osam pristupa kako, za trenutnu situaciju, odrediti koje su mjere primjenjive. Nakon primjene nekog od pristupa, broj primjenjivih mjera je sužen, ali najčešće ne dovoljno stoga se za svaki element znanja primjenjuje faktor kritičnosti koji pomaže pri određivanju mjera koje bi mogle imati najveći dorinos. Slika prikazuje korake određivanja najpovoljnijih metoda za konkretan projekt (Slika 2.).

U nastavku su detaljnije opisani postupak određivanja znanja tvrtke, kako postojećeg, tako i budućeg, s naglaskom na uočavanje onih elemenata znanja na koje treba obratiti najviše pažnje. Dodatno, je opisano osam pristupa za definiranje užeg kruga mjera u četvrtoj fazi sustavnog unaprjeđenja znanja.

## 2.2.1 Evaluacija znanja tvrtke

### 2.2.1 Evaluation of a company's knowledge

Prema [2] autori su razvili metodologiju za vrednovanje znanja tvrtke tako da se prije svega odredi dubina trenutnog znanja sa stanovišta kako zaposlenika tako i zadatka. Orijentirano na zaposlenike, to znači odrediti na kojoj je razini koji zaposlenik kompetentan u određenom elementu znanja što odražava stvarno trenutno stanje u tvrtki. S druge strane, orijentirano na zadatke, postavlja se pitanje koje su kompetencije potrebne za izvršenje zadataka, dakle iskazuje se željena situacija, tj. koliko bi zaposlenici zapravo trebali biti kompetentni. [2] Na temelju ovih saznanja kreira se matrica trenutnih kompetencija tvrtke te se dodatno

kreira scenarij zanimljiv za tvrtku. U kreiranju navedenog sudjeluju kako inženjeri tako i menadžeri. [2]

*Matrica kompetencija* svrstava pojedine elemente znanja tvrtke u četiri kategorije, u ovisnosti o stupnju upotrebe znanja (učestalost i do koje mjere se znanje upotrebljava) kako je prikazano na slici (Slika 3. lijevo). Ovisno o broju elemenata u pojedinim kategorijama tvrtka ima veću ili manju prednost na tržištu.

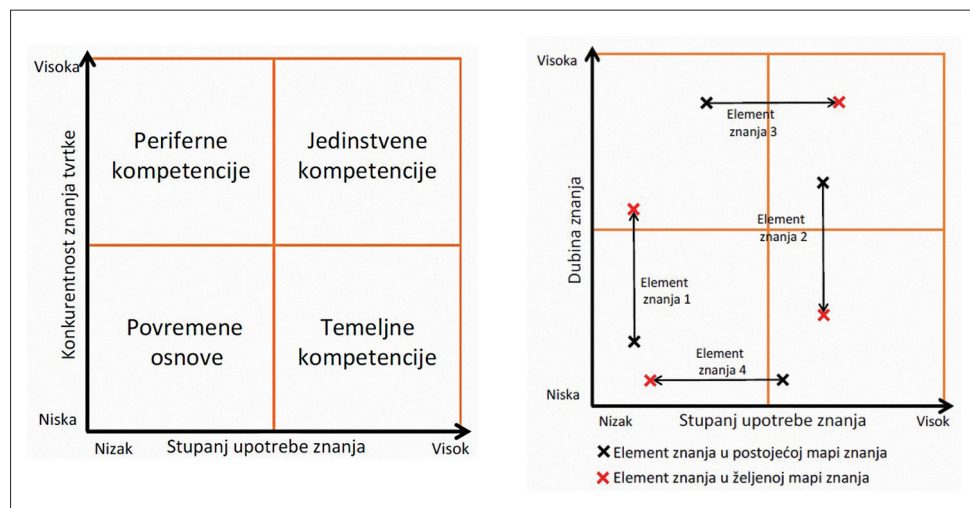
*Povremene osnove* obuhvaćaju ona znanja koja tvrtka posjeduje no treba ih samo ponekada. Unatoč samo povremenoj upotrebi, elementi znanja iz ove kategorije predstavljaju dobru osnovu za izgradnju drugih znanja koja su tvrtki u nekom trenutku potrebna.

Slično, *periferne kompetencije* također nisu često u upotrebi, no budući da su na višoj razini, tj. znanje u tvrtki ja na tom području dublje, vrijednost u vidu konkurentnosti tvrtke raste.

*Temeljne kompetencije* predstavljaju bazu znanja tvrtke i bez njih nije moguće poslovati, dok *jedinstvene kompetencije* predstavljaju visoku razinu znanja tvrtke u nekom području što toj tvrtki daje konkurentnost na tržištu.

U matrici trenutnih kompetencija, a na temelju željenih budućih kompetencija prema scenariju, kreiraju se vektori koji pokazuju smjer i veličinu potrebne promjene u nekim elementima znanja kako je prikazano na slici (Slika 3. desno).

U općem slučaju, vektori znanja ne moraju biti vodoravni ili okomiti pa ukupnu količinu potrebne promjene možemo izraziti formulom [2]:



**Slika 3**  
Matrica kompetencija (lijevo) i vektori znanja u matrici kompetencija (desno) [2]

**Figure 3**  
Competency matrix (left) and knowledge vectors in competency matrix (right) [2]

*ukupna količina promjene =*

$$\sqrt{(\text{dubina znanja})^2 + (\text{stupanj upotrebe znanja})^2} \quad (1)$$

Ovaj način zapisa pomaže pri otkrivanju kritičnih elemenata kojima je potrebno posvetiti pažnju.

## 2.2.2 Određivanje mjera za razvoj znanja iz trenutne u željenu situaciju

### 2.2.2 *Defining measures for knowledge development from the current to the desired situation*

Osam pristupa za određivanje užeg kruga mjera su sljedeći [3]:

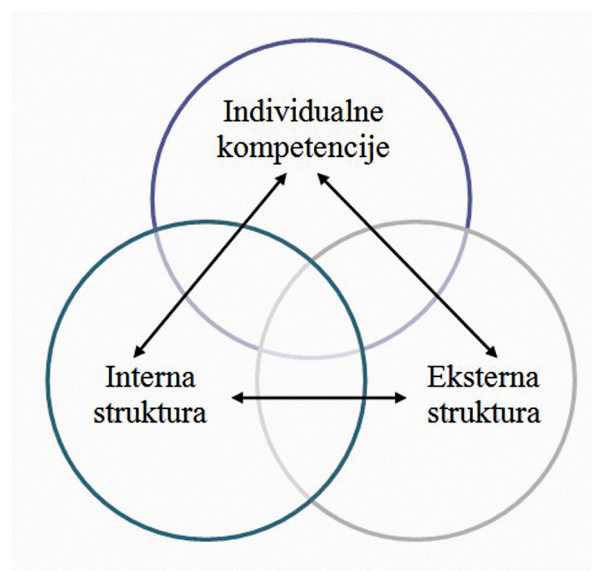
1. znanje koje dobiva na važnosti (veću pažnju potrebno je posvetiti onom znanju koje je ocijenjeno važnijim u mapi budućeg znanja, tj. onom znanju čija razina više odudara od razine u mapi postojećeg znanja)
2. zadaci koji dobivaju na važnosti (slično kao i za znanje)
3. vrsta znanja (primjerice ekspertno znanje, proceduralno znanje, znanje o proizvodu, znanje vezano uz kontakte u drugim odjelima tvrtke)
4. tip zajedničkog zadatka (ako su neki zaposlenici već radili na sličnom ili istom tipu zadatka, komunikacijskim mjerama potrebno je unaprijediti znanje onih koji sudjeluju u rješavanju zadatka trenutno)
5. jedinstveno znanje (znanje koje ima samo jedan ili nekoliko zaposlenika treba zabilježiti)
6. jedinstveni zadaci (znanje koje je nužno za neki zadatak, a samo nekoliko zaposlenika ga je upotrijebilo na potrebno je zabilježiti)
7. znanje za nove zadatke (znanje potrebno za nove zadatke treba u svakom slučaju unaprijediti)
8. izostavljanje zadataka i znanja (zadaci i znanje koji se ne spominju u scenariju interesantnom za tvrtku mogu se izostaviti u trenutnom projektu, tj. na njih ne treba trošiti resurse)

## 3. Prijenos znanja

### 3. *Knowledge transmission*

Studija slučaja provedena je u tvrtki s odjelima za istraživanje i razvoj, kao i proizvodnjom

diljem svijeta, kroz 17 intervjua s inženjerima i menadžerima projekata. Korišten je Sveibyjev model prijenosa znanja u kojemu interne i eksterne strukture čine ljudi, tj. procesi koji se odvijaju među ljudima (Slika 4.). Smjerovi strelica upućuju na smjerove prijenosa znanja pri čemu dvosmjerni prijenos znanja može značiti i suradnju prilikom stvaranja novog znanja. [5]



**Slika 4** Model prijenosa znanja [5]

**Figure 4** Knowledge transmission model [5]

Načini komunikacije koji se javljaju između pojedinih struktura i pojedinaca kada se prijenos znanja odvija u međunarodnim timovima su sljedeći [5]:

- između unutarnjih struktura: ako su članovi tima na istoj lokaciji stil razgovora je neformalan dok je među dislociranim članovima tima razgovor formalan
- između unutarnjih i vanjskih struktura: formalan i relativno oprezan pristup komunikaciji pri čemu vanjske strukture pokušavaju razumjeti partnere iz unutarnjih struktura, dok partneri iz unutarnjih struktura uglavnom potežu pitanja vezana uz zaštitu intelektualnog vlasništva i ugovore
- između pojedinaca: spremnost na suradnju
- između pojedinaca i unutarnjih struktura: strukturirana direktna komunikacija u neformalnom ili pak hijerarhijskom, formalnom tonu
- između pojedinaca i vanjskih struktura: komunikacija često u dobavljačke svrhe,

vanjski partneri često nude mogućnost neslužbene komunikacije što pojedinci prihvaćaju kako bi održali dobre odnose s dobavljačima

Važnost ovih spoznaja je u tome što otvaraju mogućnost unaprjeđenja komunikacijskih kanala među različitim sudionicima na projektu. Bilo da je riječ o komunikaciji na daljinu ili o komunikaciji "oči u oči", moguće je tehničku podršku komunikaciji prilagoditi stilovima razgovora ili pomoću tehničke podrške pokušati promijeniti stil razgovora ako se ustanovi da trenutni nije prikladan i ometa ispravnu izmjenu informacija i znanja.

#### 4. Implementacija u industriji

##### 4. *Implementation in industry*

Dok su autori [2] proveli jednu studiju evaluacije znanja temeljene na matrici kompetencija, autori [3] proveli su tri studije u različitim tvrtkama kako bi dokazali koristi navedene metodologije o sustavnom unaprjeđenju znanja. Iako uspjeh nije bio jednak u svim tvrtkama, može se zaključiti da, u slučajevima kada rezultati projekta uvelike ovise o iskustvu i vještinama voditelja sustavni pristup ima veće prednosti [3].

#### 6. Reference

##### 6. *References*

- [1] Stenholm D., Landahl J., Bergsj: Knowledge Management Life Cycle: An Individual's Perspective, Proceedings of the 13th International Design Conference DESIGN 2014
- [2] Schmidt D.M., Schenkl S.A., Maurer M.: Evaluation Of Knowledge To Future-Proof The Knowledge Base, Proceedings of the 13th International Design Conference DESIGN 2014
- [3] von Saucken C.C., Schenkl S.A., Dahmann P., Maurer M.: Measures And Methods For Systematic Knowledge Management, Proceedings of the 13th International Design Conference DESIGN 2014
- [4] Wickel M. C., Schenkl S. A., Schmidt D. M., Hense J., Mandl H., Maurer M.,: Knowledge structure maps based on Multiple Domain Matrices, InImpact: The Journal of Innovation Impact: Vol. 5 No.1: pp.5 - 16
- [5] Holmqvist J., Ericson Å.: How Global Teams Share Experiences – A Study Of Cultural Differences, Proceedings of the 13th International Design Conference DESIGN 2014

Faze definiranja ciljeva te kreiranje postojeće i buduće mape znanja mogu pomoći menadžmentu za bolji uvid u eventualne troškove koji mogu nastati zbog nedostatka znanja. Dodatno, pomoć pri nalaženju adekvatnih mjera za rješavanje problema nedostatka znanja može koristiti prilikom evaluacije troškova projekta već u ranim fazama.

#### 5. Zaključak

##### 5. *Conclusion*

Sve spomenute metode temelje se prije svega na razgovoru s ljudima (inženjerima, menadžerima i drugim odgovornima), a često traže od ljudi da sami procjenjuju svoje vještine. Odgovori na takav zadatak ne mogu biti objektivni, a ljudi često griješe u procjeni vlastitih sposobnosti. Budući da se većina metodologija temelji upravo na procijenjenim sposobnostima ljudi, to je ujedno i najveća mana spomenutih metoda. Međutim, u nedostatku mogućnosti za objektivniju procjenu kompetencija, već je i samoprocjena dovoljna da bi se napredovalo u području upravljanja znanjem. Pojedine tvrtke mogu tako poći u smjeru bolje organizacije timova i boljeg iskorištavanja resursa, boljeg planiranja budžeta (primjerice uključivanje troškova stručnog osposobljavanja u budžet projekta), pa čak i rezanja troškova tamo gdje je to moguće kada je riječ o razvoju elemenata znanja.

**AUTORI · AUTHORS****Petra Močibov**

Petra Močibov, mag. ing. mech., rođena je 1.10.1990. godine u Zagrebu gdje je, po završetku matematičkog smjera V. gimnazije, 2009. upisala sveučilišni studij strojarstva na

Fakultetu strojarstva i brodogradnje. Usmjerivši se na konstruiranje i razvoj proizvoda, diplomski je rad izradila u suradnji s tvrtkom Robert Bosch GmbH te magistrirala 2015. godine. Od 2012. godine prisustvuje međunarodnim konferencijama na temu znanosti o konstruiranju (DESIGN 2012, DESIGN 2014, ICED 2015), a od 2015. radi za koncern Stanley Black&Decker GmbH. Budućim akademskim i industrijskim aktivnostima želja joj je doprinijeti praktičnom upravljanju znanjem te komunikaciji među suradnicima u procesu razvoja novih proizvoda.

**Korespondencija:**

pmocibov@gmail.com

**Nenad Bojčetić**

Izv. prof. dr. sc. Nenad Bojčetić – izvanredni je profesor na Katedri za konstruiranje i razvoj proizvoda na Fakultetu strojarstva i brodogradnje, Sveučilište u Zagrebu. Diplomirao je 1991.

godine na istom fakultetu gdje je 1996. godine obranio magistarski rad, a 2000. godine doktorsku disertaciju. Objavio je veći broj znanstvenih i stručnih članaka te jednu knjigu. Član je međunarodne organizacije “Design Society”. Područje djelovanja CAD, PDM/PLM, upravljanje znanjem, razvoj alata i sustava za proširenje i prilagodbu mogućnosti IT sustava u industriji.

**Korespondencija:**

nenad.bojcetic@fsb.hr