

Pregledni rad
UDK: 007:519.237.7

Dr. sc. Jovana Zoroja¹

**PRIMJENA FAKTORSKE ANALIZE U ISTRAŽIVANJU
KORIŠTENJA INFORMACIJSKO-KOMUNIKACIJSKIH
TEHNOLOGIJA: PRIMJER EUROPSKIH ZEMALJA**

**APPLICATION OF FACTOR ANALYSIS IN RESEARCHING
THE USAGE OF INFORMATION AND COMMUNICATION
TECHNOLOGIES: THE CASE OF EUROPEAN COUNTRIES**

SAŽETAK: Razvoj i implementacija informacijsko-komunikacijskih tehnologija značajno utječe na odvijanje poslovanja, ali i svakodnevnih aktivnosti pojedinaca. Upravo zemlje u kojima se u velikoj mjeri koriste informacijsko-komunikacijske tehnologije, konkurentnije su te ekonomski i društveno prednjače u odnosu na zemlje u kojima se informacijsko-komunikacijske tehnologije ne primjenjuju u tolikoj mjeri. Korištenje informacijsko-komunikacijskih tehnologija predstavlja jedan od glavnih pokazatelja gospodarskoga razvoja zemalja. Postoje brojni pokazatelji kojima je moguće mjeriti korištenje informacijsko-komunikacijskih tehnologija. Namjera istraživanja prikazanoga u ovome radu je istražiti je li moguće sažeti veliki broj pokazatelja korištenja informacijsko-komunikacijskih tehnologija na manji broj grupa korištenjem faktorske analize. Predmet istraživanja su brojni pokazatelji o korištenju informacijsko-komunikacijskih tehnologija koji su sadržani u statističkoj bazi Europske komisije – Eurostat u odjeljku Informacijsko društvo. Na prikupljenim podacima provedena je faktorska analiza kako bi se od većega broja izvornih varijabli izlučio manji broj faktora kojima se može zbirno opisati korištenje informacijsko-komunikacijskih tehnologija. Provedeno istraživanje rezultiralo je s tri izlučena faktora, koji se odnose na aktivnosti pojedinaca na internetu, aktivnosti tvrtki u području uvoza i izvoza visokih tehnologija i elektroničkoga poslovanja tvrtki.

KLJUČNE RIJEČI: informacijsko-komunikacijske tehnologije, faktorska analiza, internet, europske zemlje.

ABSTRACT: Development and implementation of information and communication technologies has significant impact on business activities of the companies and private life of individuals. Usage of information and communication technologies is one of the main indicators of the economic development. Countries which encourage usage of information and communication technologies are more competitive and more developed. There are a

¹ Dr. sc. Jovana Zoroja, Ekonomski fakultet – Zagreb, Trg J. F. Kennedyja 6, 10000 Zagreb.

huge number of indicators which can be used for measuring information and communication technologies.

The purpose of the research presented in this paper is to investigate if it is possible to reduce a large number of indicators of the usage of information and communication technologies into a smaller number of groups using factor analysis. Subject of the research are many indicators of usage of information and communication technologies which can be found in the statistical database of the European Commission – Eurostat in the section Information society. On selected data factor analysis was made and from larger number of variables a smaller number of factors are given which are then used to describe usage of information and communication technologies. The conducted research resulted with three factors, regarding activity of individuals on the Internet, business activity of the firms in export and import of high technologies and electronic business.

KEY WORDS: information-communication technologies, factor analysis, Internet, european countries.

1. UVOD

Informacijsko društvo se može definirati kao društvo koje potiče razvoj, implementaciju i korištenje informacijsko-komunikacijskih tehnologija u svim dijelovima društva i gospodarstva, a sve s ciljem daljnjega razvoja i napretka (Misuraca *et al.*, 2013.). Informacijsko-komunikacijske tehnologije predstavljaju široki spektar suvremenih tehnologija za elektroničku obradu podataka i prijenos podataka na daljinu čime je omogućena komunikacija među korisnicima kroz razmjenu točnih, potpunih, relevantnih i pravodobnih informacija, i to u području obrazovanja, poslovanja, znanosti, javne uprave, financija (Akman, Mishra, 2010.; Panian *et al.*, 2005.). Upravo je sektor informacijsko-komunikacijskih tehnologija jedan od najrazvijenijih u zadnjih nekoliko godina, a očekuje se njegov brzi razvoj i u budućnosti (Gu, Jung, 2013.). U europskim zemljama sektor informacijsko-komunikacijskih tehnologija predstavlja jedan od osnovnih izvora rasta produktivnosti (Tambe, Hitt, 2012.; Blackman, 2004.). Informacijsko-komunikacijske tehnologije potiču razvoj inovacija, potiču zapošljavanje, konkurentnost, rast i razvoj ostalih gospodarskih sektora (Lehner *et al.*, 2013.). Također, prednosti korištenja informacijsko-komunikacijskih tehnologija značajno se ističu u načinu komunikacije između pojedinaca, ali i zaposlenika. Osim toga, korištenje informacijsko-komunikacijskih tehnologija u obrazovanju uvelike je pridonijelo napretku kurikuluma i zadovoljstvu studenata (Katz, 2014.). Pozitivni učinci primjene informacijsko-komunikacijskih tehnologija očituju se i u zdravstvu, kao i u financijskome sektoru, trgovini i radu javnih organizacija (Khalil, 2011.; Anttiroiko, 2001.). Može se zaključiti kako informacijsko-komunikacijske tehnologije zahvaljujući svome brzom razvoju značajno doprinose društvenome i ekonomskome napretku zemalja.

Najrazvijenije zemlje svijeta ulažu značajna sredstva u daljnji razvoj i napredak informacijsko-komunikacijskih tehnologija, jer one predstavljaju jedan od osnovnih čimbenika ostvarivanja konkurentne prednosti. Također, primjena informacijsko-komunikacijskih tehnologija uvelike poboljšava kvalitetu i životni standard stanovnika (Cilan *et al.*, 2009.). Upravo zbog navedenih prednosti primjene informacijsko-komunikacijskih tehnologija, većina zemalja je izradila smjernice, programe, politike, strategije s namjerom poticanja

daljnega korištenja informacijsko-komunikacijskih tehnologija, ali i s ciljem mjerenja njihovoga utjecaj na razvoj gospodarstva.

Korištenje informacijsko-komunikacijskih tehnologija nije moguće iskazati kroz jednu varijablu, zbog velikoga broja područja njihove primjene. Mnoštvo je pokazatelja kojima se provode mjerenja korištenja informacijsko-komunikacijskih tehnologija kako bi se utvrdile smjernice daljnega razvoja zemalja u razvoju koje zaostaju u primjeni informacijsko-komunikacijskih tehnologija, ali i kako bi se dodatno unaprijedila njihova primjena u razvijenim zemljama. S obzirom na mnoštvo varijabli kojima je moguće mjeriti korištenje informacijsko-komunikacijskih tehnologija, ističu se dva cilja rada. Prvi cilj rada je pokazati i navesti brojne pokazatelje korištenja informacijsko-komunikacijskih tehnologija iz različitih izvora. Drugi cilj rada je primjenom faktorske analize pokazatelja korištenja informacijsko-komunikacijskih tehnologija za 2011. godinu svesti veći broj pokazatelja na manji broj osnovnih grupa odabranih varijabli.

Provedeno empirijsko istraživanje obuhvatilo je pet područja primjene informacijsko-komunikacijskih tehnologija: e-učenje, aktivnosti pojedinaca na internetu, elektroničko poslovanje tvrtki, e-znanost i elektronička javna uprava, odnosno 17 varijabli. Na izabranim podacima provedena je faktorska analiza s ciljem sažimanja većega broja međusobno povezanih varijabli u manji broj s ciljem definiranja njihove povezanosti, kao i utvrđivanja zajedničkih značajki (Lee, Lee, 2011.). Osim u navedenu svrhu, faktorska analiza koristi se i za otkrivanje strukture povezanosti među varijablama i za testiranje unaprijed postavljenih hipoteza o povezanosti pojedinih varijabli (Hair *et al.*, 2005.). Primjenom faktorske analize utvrđene su osnovne grupe pokazatelja korištenja informacijsko-komunikacijskih tehnologija za 2011. godinu.

Rad se sastoji od šest cjelina. U prvome, uvodnome dijelu rada, naveden je razvoj i značaj korištenja informacijsko-komunikacijskih tehnologija. U drugome dijelu prikazan je pregled korištenja informacijsko-komunikacijskih tehnologija. U trećemu dijelu opisana je metodologija istraživanja. U četvrtome dijelu predstavljeni su dobiveni rezultati nakon provedene faktorske analize. U petome dijelu opisani su dobiveni rezultati. U zadnjemu, zaključnome dijelu rada, dani su zaključci provedene analize, definirana su ograničenja prilikom pisanja rada, a navedene su i preporuke za buduća istraživanja.

2. PREGLED MJERENJA KORIŠTENJA INFORMACIJSKO-KOMUNIKACIJSKIH TEHNOLOGIJA

Mnoštvo je pokazatelja koji se koriste prilikom mjerenja korištenja informacijsko-komunikacijskih tehnologija, s obzirom na mogućnosti njihove primjene u obrazovanju, znanosti, financijama, javnoj upravi i poslovanju.

Kvalitetan izvor podataka o korištenju informacijsko-komunikacijskih tehnologija, njihovome razvoju i utjecaju je Eurostat – statistička baza Europske komisije i dvije studije: (i) Indeks razvijenosti informacijsko-komunikacijskih tehnologija, i (ii) Globalno izvješće o informacijsko-komunikacijskim tehnologijama.

Eurostat već dugi niz godina vodi statistiku o korištenju informacijsko-komunikacijskih tehnologija kroz razna istraživanja. U lipnju 2014. godine Eurostat je vodio evidenciju

o 183 varijable koje evidentiraju ponašanje pojedinaca i organizacija kroz anketna istraživanja. Svake godine, povećava se broj pokazatelja korištenja informacijsko-komunikacijskih tehnologija. U 2013. godini Eurostat je vodio evidenciju o 159 varijabli, što znači da se za godinu dana broj varijabli povećao za 24. Navedeni podatak upućuje na činjenicu kako se informacijsko-komunikacijske tehnologije vrlo brzo razvijaju i kako se povećava njihova primjena, što znači da je potrebno povećati i broj varijabli kojima se mjeri njihovo korištenje. Također, svake godine, povećava se i dostupnost varijabli za pojedine zemlje. Najveći broj podataka dostupan je od 2000. godine, i to većinom za tadašnje zemlje Europske unije. Kao što se i broj varijabli kojima se mjeri korištenje informacijsko-komunikacijskih tehnologija povećava, tako se povećava i broj dostupnih podataka za zemlje članice Europske unije, za zemlje kandidatkinje, ali i za ostale europske zemlje.

Tablica 1. Prikaz Informacijskog društva prema šest osnovnih grupa pokazatelja

Informacijsko društvo – statistički podaci	
1. Osnovni pokazatelji	51 pokazatelj
2. Telekomunikacijske usluge	27 pokazatelja
3. Korištenje računala i interneta od strane pojedinaca i tvrtki	75 pokazatelja
4. Elektronička trgovina namijenjena pojedincima i tvrtkama	11 pokazatelja
5. Informatičke vještine pojedinaca i zaposlenika u tvrtkama	14 pokazatelja
6. Informacijsko društvo – regionalni statistički podaci	5 pokazatelja
Ukupno	183 pokazatelja

Izvor: Istraživanje autora prema Eurostatu (2014.).

Statistički podaci koji se prikupljaju i analiziraju unutar Eurostata podijeljeni su na devet osnovnih pokazatelja: opći podaci; ekonomski i financijski podaci; stanovništvo i socijalni uvjeti; industrija, trgovina i usluge; poljoprivreda i ribolov; međunarodna trgovina; prijevoz; okoliš i energija, i znanost i tehnologija. Unutar kategorije industrija, trgovina i usluge nalazi se šest podkategorija, a jedna od njih je Informacijsko društvo – statistički podaci. Prema podacima iz tablice 1. može se uočiti kako se podkategorija Informacijsko društvo dijeli na šest glavnih pokazatelja koji zajedno sadrže 183 varijable, a koje su podijeljene na sljedeće kategorije: osnovni pokazatelji, telekomunikacijske usluge, korištenje računala i interneta od strane pojedinaca i tvrtki, elektronička trgovina namijenjena pojedincima i tvrtkama, posjedovanje informatičkih vještina pojedinaca i zaposlenika u tvrtkama te podaci o korištenju informacijsko-komunikacijskih tehnologija prema regijama Europe. Podaci se vode za 34 europske zemlje, te za Kanadu, Sjedinjene Američke Države i Južnu Koreju. Nije moguće za svaku godinu i za svaki pokazatelj pronaći podatak za svaku zemlju, ali većina podataka postoji, pogotovo unatrag nekoliko godina.

Indeks razvijenosti informacijsko-komunikacijskih tehnologija također predstavlja zbrojni prikaz korištenja informacijsko-komunikacijskih tehnologija, ali na svjetskoj razini (International Telecommunication Union, 2013.). Navedeni indeks se sastoji od 11 pokazatelja koji su podijeljeni unutar tri podindeksa: (i) pristup informacijsko-komunikacijskim tehnologijama, (ii) korištenje informacijsko-komunikacijskih tehnologija, i (iii) vještine korištenja informacijsko-komunikacijskih tehnologija. Svake godine se povećava broj ze-

malja koje su obuhvaćene indeksom, a u 2013. godini navedeni su podaci za 157 zemalja. S obzirom na prikupljene i analizirane podatke za 157 zemalja u razvoju i razvijenih zemalja Indeks razvijenosti informacijsko-komunikacijskih tehnologija daje uvid prema zemljama u: (i) stupnju razvoja informacijsko-komunikacijskih tehnologija, (ii) napretku u razvoju informacijsko-komunikacijskih tehnologija, i (iii) potencijalu daljnjega razvoja informacijsko-komunikacijskih tehnologija.

Važno je istaknuti i Globalno izvješće o informacijsko-komunikacijskim tehnologijama kao još jednu studiju koja mjeri razvoj i korištenje informacijsko-komunikacijskih tehnologija (Bilbao-Osorio *et al.*, 2013.). Glavni cilj Globalnog izvješća o informacijsko-komunikacijskim tehnologijama jest pratiti napredak i utjecaj informacijsko-komunikacijskih tehnologija u zemljama u razvoju i u razvijenim zemljama kroz indeks mrežne spremnosti. U 2013. godini Globalno izvješće o informacijsko-komunikacijskim tehnologijama obuhvatilo je podatke za 144 zemlje, a sastojalo se od 54 varijable. Indeks mrežne spremnosti daje uvid u: (i) spremnost korištenja i implementacije informacijsko-komunikacijskih tehnologija od strane pojedinaca, tvrtki i javnih organizacija, (ii) infrastrukturu informacijsko-komunikacijskih tehnologija, i (iii) utjecaj koji razvoj i korištenje informacijsko-komunikacijskih tehnologija ima na napredak zemalja.

3. METODOLOGIJA ISTRAŽIVANJA

3.1. Države i godina provođenja istraživanja

Podaci o korištenju informacijsko-komunikacijskih tehnologija prikupili su se za države Europske unije (28 država članica), za tri države kandidatkinje (Island, Makedoniju i Tursku) i za Norvešku. Ostale europske zemlje nisu uključene u analizu, jer za njih nisu bili dostupni podaci za 2011. godinu za sve odabrane varijable. Podaci su prikupljeni za 17 varijabli za 2011. godinu.

3.2. Opis i odabir varijabli

Varijable korištene u analizi odabrane su prema nekoliko osnovnih područja primjene informacijsko-komunikacijskih tehnologija: e-učenje, e-znanost, elektroničko poslovanje, elektronička javna uprava (Blackman, 2004.; Shareef *et al.*, 2011.; Dünnebeil *et al.*, 2012.). Podaci za odabrane pokazatelje korištenja informacijsko-komunikacijskih tehnologija prikupljeni su iz statističke baze Europske komisije - Eurostat iz odjeljka Informacijsko društvo.

Tablica 2. Pokazatelji korištenja informacijsko-komunikacijskih tehnologija podijeljeni unutar pet osnovnih područja

<i>Područje 1: E-učenje namijenjeno pojedincima</i>	
EUP_1: Kupovina sredstava za e-učenje	Postotak pojedinaca od 16 do 74 godine, 2011. godina
EUP_2: Traženje informacija o obrazovanju, obuci i tečajevima	
EUP_3: Korištenje interneta za obuku i obrazovanje	
EUP_4: Korištenje interneta za donošenje odluka o obrazovanju	
<i>Područje 2: Aktivnosti pojedinaca na internetu</i>	
EBP_1: Korištenje internetskog bankarstva	Postotak pojedinaca od 16 do 74 godine, 2011. godina
EZP_1: Korištenje interneta za traženje zaposlenja	
<i>Područje 3: Aktivnosti tvrtki na internetu</i>	
EPT_1: Korištenje CRM softvera	Postotak svih tvrtki, osim financijskih s najmanje 10 zaposlenika, 2011. godina
EPT_2: Kupovina putem interneta	
EPT_3: Naručivanje putem interneta	
<i>Područje 4: E-znanost - uvoz i izvoz visokih tehnologija</i>	
EZ_1: Uvoz visokih tehnologija unutar EU27 (% ukupnog uvoza)	Postotak ukupnog uvoza i izvoza visokih tehnologija unutar i izvan država Europske unije i u svijetu, 2011. godina
EZ_2: Uvoz visokih tehnologija izvan EU27 (% ukupnog uvoza)	
EZ_3: Uvoz visokih tehnologija u svijetu (% ukupnog uvoza)	
EZ_4: Izvoz visokih tehnologija unutar EU27 (% ukupnog izvoza)	
EZ_5: Izvoz visokih tehnologija izvan EU27 (% ukupnog izvoza)	
EZ_6: Izvoz visokih tehnologija u svijetu (% ukupnog izvoza)	
<i>Područje 5: E-javna uprava (pojedinci)</i>	
EJUP_1: Slanje obrazaca putem stranica javne uprave	Postotak pojedinaca od 16 do 74 godine, 2011. godina
EJUP_2: Komunikacija s organizacijama javne uprave	

Izvor: Istraživanje autora prema Eurostatu (2014.).

Za svako navedeno područje izabrane su od dvije do šest varijabli, ovisno o dostupnosti podataka za 2011. godinu za odabrane europske zemlje. Ukupan broj varijabli je 17, a podijeljene su unutar pet područja informacijsko-komunikacijskih tehnologija: e-učenje, aktivnosti pojedinaca na internetu, aktivnosti tvrtki na internetu, e-znanost – uvoz i izvoz visokih tehnologija i e-javna uprava. Također, odabrane varijable kojima se mjeri korištenje informacijsko-komunikacijskih tehnologija odnose se i na pojedinca, ali i na tvrtke. Tablica 2. prikazuje naziv, jedinicu analize, mjernu jedinicu i godinu za svaku pojedinu varijablu.

3.3. Statistička analiza

S obzirom da se radi o većem broju pokazatelja korištenja informacijsko-komunikacijskih tehnologija primijenila se faktorska analiza kako bi se definirao manji broj grupa pokazatelja korištenja informacijsko-komunikacijskih tehnologija. U provođenju faktorske analize definirali su se sljedeći koraci. Prvo je utvrđena Kaiser-Meyer-Olkinova mjera kako bi se potvrdila prikladnost prikupljenih podataka za primjenu faktorske analize. Na osnovi svojstvenih vrijednosti većih od jedan i Catellijevega dijagrama izlučena su tri faktora. Potom je provedena Varimax rotacija faktora. Za empirijsku analizu podataka koristio se programski alat Statistica.

3.4. Karakteristike uzorka

Prilikom opisa 17 varijabli pokazatelja korištenja informacijsko-komunikacijskih tehnologija podijeljenih unutar pet područja koristila se deskriptivna statistika (minimum, maksimum, prosjek i standardna devijacija).

Prosječna vrijednost korištenja e-učenja od strane pojedinaca u 2011. godini najniža je za varijablu EUP_1: Kupovina sredstava za e-učenje, dok je viša za ostale varijable. Pojedinci su najviše koristili internet za obuku i obrazovanje (EUP_3) i za donošenje odluka o obrazovanju (EUP_4), dok nešto niže za traženje informacija o obrazovanju, obuci i tečajevima (EUP_2).

Prosječne vrijednosti korištenja interneta od strane pojedinaca prilikom obavljanja bankarskih usluga (EBP_1) i traženja zaposlenja (EZP_1) su za obje promatrane varijable približno jednake u 2011. godini.

Prosječne vrijednosti elektroničkoga poslovanja tvrtki u promatranome razdoblju pokazuju veća međusobna odstupanja. Najveću prosječnu ocjenu ima varijabla EPT_1, koja se odnosi na korištenje CRM softvera odnosno upravljanje odnosom s klijentima čime tvrtke održavaju dobre veze s postojećim klijentima te pridobivaju nove, a sve pozitivno utječe na poslovanje. Nižu prosječnu ocjenu ima varijabla EPT_3, koja se odnosi na naručivanje putem interneta dok tvrtke najmanje koriste kupovinu putem interneta (EPT_2).

Varijabla EZ_6: Izvoz visokih tehnologija u svijetu ima najveću prosječnu vrijednost u odnosu na ostalih pet varijabli. Približno jednake prosječne vrijednosti su za varijable EZ_1: Uvoz visokih tehnologija unutar EU27, EZ_3: Uvoz visokih tehnologija u svijetu, EZ_4: Izvoz visokih tehnologija unutar EU27 i EZ_5: Izvoz visokih tehnologija izvan EU27. Najmanja prosječna vrijednost je za varijablu EZ_2, koja se odnosi na uvoz visokih tehnologija izvan EU27.

Prosječne vrijednosti korištenja usluga javne uprave putem interneta od strane pojedinaca u 2011. godini se uvelike razlikuju. Pojedinci odabranih europskih zemalja dvostruko su više koristili internet za komunikaciju s organizacijama javne uprave (varijabla EJUP_2), nego za slanje obrazaca putem stranica javne uprave (varijabla EJUP_1).

Tablica 3. Deskriptivna statistika pokazatelja korištenja informacijsko-komunikacijskih tehnologija, 2011. godina

E-učenje namijenjeno pojedincima	N	Minimum	Maksimum	Prosjek	Standardna devijacija
EUP_1: Kupovina sredstava za e-učenje	32	1,0	43,0	13,8	11,9
EUP_2: Traženje informacija o obrazovanju, obuci i tečajevima	32	10,0	54,0	29,7	10,8
EUP_3: Korištenje interneta za obuku i obrazovanje	32	13,0	75,0	39,2	16,2
EUP_4: Korištenje interneta za donošenje odluka o obrazovanju	32	5,0	71,0	33,3	16,3
<i>Aktivnosti pojedinaca na internetu</i>	N	Minimum	Maksimum	Prosjek	Standardna devijacija
EBP_1: Korištenje internetskog bankarstva	32	3,0	85,0	40,3	25,1
EZP_1: Korištenje interneta za traženje zaposlenja	32	4,0	30,0	17,4	6,9
<i>Aktivnosti tvrtki na internetu</i>	N	Minimum	Maksimum	Prosjek	Standardna devijacija
EPT_1: Korištenje CRM softvera	32	7,0	29,0	18,3	5,1
EPT_2: Kupovina putem interneta	32	0	51,0	23,8	15,5
EPT_3: Naručivanje putem interneta	32	3,0	31,0	14,1	7,2
<i>E-znanost – uvoz i izvoz visokih tehnologija</i>	N	Minimum	Maksimum	Prosjek	Standardna devijacija
EZ_1: Uvoz visokih tehnologija unutar EU27 (% ukupnog uvoza)	32	4,9	45,0	10,9	6,8
EZ_2: Uvoz visokih tehnologija izvan EU27 (% ukupnog uvoza)	32	2,0	57,1	15,4	11,7
EZ_3: Uvoz visokih tehnologija u svijetu (% ukupnog uvoza)	32	4,8	45,0	12,3	7,3
EZ_4: Izvoz visokih tehnologija unutar EU27 (% ukupnog izvoza)	32	0,7	26,0	9,2	6,4
EZ_5: Izvoz visokih tehnologija izvan EU27 (% ukupnog izvoza)	32	1,6	45,0	14,1	11,8
EZ_6: Izvoz visokih tehnologija u svijetu (% ukupnog izvoza)	32	1,6	30,1	10,8	7,7
<i>E-javna uprava namijenjena pojedincima</i>	N	Minimum	Maksimum	Prosjek	Standardna devijacija
EJUP_1: Slanje obrazaca putem stranica javne uprave	32	2,0	50,0	16,2	13,0
EJUP_2: Komunikacija s organizacijama javne uprave	32	7,0	77,0	34,3	19,2

Izvor: Istraživanje autora prema Eurostatu (2014.).

4. REZULTATI ISTRAŽIVANJA

Dobiveni rezultati provedene faktorske analize prikazani su u sljedećim tablicama. U tablici 4. prikazane su vrijednosti Kaiser-Meyer-Olkinove mjere za svaku od odabranih 17 varijabli. Cilj provođenja Kaiser-Meyer-Olkinove mjere je utvrđivanje prikladnosti podataka za primjenu faktorske analize. Drugim riječima Kaiser-Meyer-Olkinova mjera treba biti veća od 0,5 kako bi se mogli izlučiti faktori. Iz tablice 4. može se uočiti kako su pojedinačne Kaiser-Meyer-Olkinove mjere veće od 0,5 za svaku varijablu (Hair *et al.*, 2005.). Jedina iznimka je varijabla čija je vrijednost Kaiser-Meyer-Olkinove mjere približno jednaka 0,5 (EZ_1: Uvoz visokih tehnologija unutar EU27 (% ukupnog uvoza)) i iznosi 0,452.

Tablica 4. Kaiser-Meyer-Olkinove mjere za faktorsku analizu pokazatelja korištenja informacijsko-komunikacijskih tehnologija; 2011. godina

Područja	Naziv varijable	Kaiser-Meyer-Olkinova mjera
E-učenje namijenjeno pojedincima	EUP_1: Kupovina sredstava za e-učenje	0,779
	EUP_2: Traženje informacija o obrazovanju, obuci i tečajevima	0,725
	EUP_3: Korištenje interneta za obuku i obrazovanje	0,858
	EUP_4: Korištenje interneta za donošenje odluka o obrazovanju	0,749
Aktivnosti pojedinaca na internetu	EBP_1: Korištenje internetskog bankarstva	0,858
	EZP_1: Korištenje interneta za traženje zaposlenja	0,688
Aktivnosti tvrtki na internetu	EPT_1: Korištenje CRM softvera	0,742
	EPT_2: Kupovina putem interneta	0,864
	EPT_3: Naručivanje putem interneta	0,715
E-znanost – uvoz i izvoz visokih tehnologija	EZ_1: Uvoz visokih tehnologija unutar EU27 (% ukupnog uvoza)	0,452
	EZ_2: Uvoz visokih tehnologija izvan EU27 (% ukupnog uvoza)	0,795
	EZ_3: Uvoz visokih tehnologija u svijetu (% ukupnog uvoza)	0,913
	EZ_4: Izvoz visokih tehnologija unutar EU27 (% ukupnog izvoza)	0,804
	EZ_5: Izvoz visokih tehnologija izvan EU27 (% ukupnog izvoza)	0,916
	EZ_6: Izvoz visokih tehnologija u svijetu (% ukupnog izvoza)	0,944
E-javna uprava (pojedinci)	EJUP_1: Slanje obrazaca putem stranica javne uprave	0,765
	EJUP_2: Komunikacija s organizacijama javne uprave	0,923

Izvor: Istraživanje autora prema Eurostatu (2014.).


U tablici 5. prikazane su svojstvene vrijednosti, pojedinačni i kumulativni postoci varijance faktora. Izlučuju se samo oni faktori čije su svojstvene vrijednosti veće od jedan, što znači kako je moguće izlučiti tri faktora, budući su tri svojstvene vrijednosti veće od jedan.

Tablica 5. Rezultati provedene faktorske analize za pokazatelje korištenja informacijsko-komunikacijskih tehnologija; 2011. godina

Područja	Varijable	Svojstvena vrijednost	Postotak varijance	Kumulativni postotak varijance
E-učenje namijenjeno pojedincima	EUP_1: Kupovina sredstava za e-učenje	8.087	47.579	47.579
	EUP_2: Traženje informacija o obrazovanju, obuci i tečajevima	4.075	23.969	71.548
	EUP_3: Korištenje interneta za obuku i obrazovanje	1.326	7.799	79.347
	EUP_4: Korištenje interneta za donošenje odluka o obrazovanju	0.900	5.296	84.644
Aktivnosti pojedinaca na internetu	EBP_1: Korištenje internetskog bankarstva	0.685	4.028	88.672
	EZP_1: Korištenje interneta za traženje zaposlenja	0.486	2.859	91.531
Aktivnosti tvrtki na internetu	EPT_1: Korištenje CRM softvera	0.434	2.551	94.082
	EPT_2: Kupovina putem interneta	0.251	1.475	95.557
	EPT_3: Naručivanje putem interneta	0.245	1.441	96.998
E-znanost	EZ_1: Uvoz visokih tehnologija unutar EU27 (% ukupnog uvoza)	0.176	1.037	98.035
	EZ_2: Uvoz visokih tehnologija izvan EU27 (% ukupnog uvoza)	0.128	0.751	98.786
	EZ_3: Uvoz visokih tehnologija u svijetu (% ukupnog uvoza)	0.084	0.496	99.282
	EZ_4: Izvoz visokih tehnologija unutar EU27 (% ukupnog izvoza)	0.060	0.352	99.634
	EZ_5: Izvoz visokih tehnologija izvan EU27 (% ukupnog izvoza)	0.028	0.167	99.801
	EZ_6: Izvoz visokih tehnologija u svijetu (% ukupnog izvoza)	0.021	0.121	99.921
E-javna uprava (pojedinci)	EJUP_1: Slanje obrazaca putem stranica javne uprave	0.008	0.046	99.967
	EJUP_2: Komunikacija s organizacijama javne uprave	0.006	0.033	100.000
Ukupno		17.000	100.00	-

Izvor: Istraživanje autora prema Eurostatu (2014.).

Catellijev dijagram za faktorsku analizu pokazatelja korištenja informacijsko-komunikacijskih tehnologija za 2011. godinu prikazan je na grafikonu 1. Prema grafičkim podacima može se uočiti kako se izdvajaju tri faktora čije su svojstvene vrijednosti vizualno odvojene od ostalih svojstvenih vrijednosti preostalih faktora.



Grafikon 1. Catellijev dijagram za faktorsku analizu pokazatelja korištenja informacijsko-komunikacijskih tehnologija; 2011. godina

Izvor: Istraživanje autora prema Eurostatu (2014.).

Tablica 6. prikazuje matricu faktorske strukture nakon Varimax rotacije faktora za pokazatelje korištenja informacijsko-komunikacijskih tehnologija za 2011. godinu. Kao što je prethodna analiza pokazala (tablica 5. i grafikon 1.), izlučena su tri faktora (tablica 6.). Označene su vrijednosti faktora koje su veće od 0,5 što upućuje na zaključak kako su izlučena tri faktora pokazatelja korištenja informacijsko-komunikacijskih tehnologija za 2011. godinu.

Tablica 6. Matrica faktorske strukture nakon Varimax rotacije faktora za pokazatelje korištenja informacijsko-komunikacijskih tehnologija; 2011. godina

Područja	Varijable	Faktori		
		1.	2.	3.
E-učenje namijenjeno pojedincima	EUP_1: Kupovina sredstava za e-učenje	0.675	0.381	0.423
	EUP_2: Traženje informacija o obrazovanju, obuci i tečajevima	0.835	0.150	0.065
	EUP_3: Korištenje interneta za obuku i obrazovanje	0.905	0.096	0.171
	EUP_4: Korištenje interneta za donošenje odluka o obrazovanju	0.857	0.058	0.100
Aktivnosti pojedinaца na internetu	EBP_1: Korištenje internetskog bankarstva	0.836	0.128	0.376
	EZP_2: Korištenje interneta za traženje zaposlenja	0.811	0.083	0.154
Aktivnosti tvrtki na internetu	EPT_1: Korištenje CRM softvera	0.159	-0.026	0.846
	EPT_2: Kupovina putem interneta	0.404	0.277	0.790
	EPT_3: Naručivanje putem interneta	0.412	0.177	0.717
E-znanost – uvoz i izvoz visokih tehnologija	EZ_1: Uvoz visokih tehnologija unutar EU27 (% ukupnog uvoza)	0.064	0.653	0.147
	EZ_2: Uvoz visokih tehnologija izvan EU27 (% ukupnog uvoza)	0.129	0.881	0.048
	EZ_3: Uvoz visokih tehnologija u svijetu (% ukupnog uvoza)	0.115	0.936	0.156
	EZ_4: Izvoz visokih tehnologija unutar EU27 (% ukupnog izvoza)	-0.009	0.896	0.035
	EZ_5: Izvoz visokih tehnologija izvan EU27 (% ukupnog izvoza)	0.192	0.937	0.028
	EZ_6: Izvoz visokih tehnologija u svijetu (% ukupnog izvoza)	0.074	0.968	0.048
E-javna uprava (pojedinci)	EJUP_1: Slanje obrazaca putem stranica javne uprave	0.848	-0.009	0.214
	EJUP_2: Komunikacija s organizacijama javne uprave	0.920	0.067	0.268

Izvor: Istraživanje autora prema Eurostatu (2014.).

5. RASPRAVA

Prilikom interpretacije faktora polazi se od matrice faktorske strukture nakon provedene Varimax rotacije faktora i utvrđivanja varijabli koje imaju faktorska opterećenja. Na osnovi analiziranih i dobivenih podataka lako se može uočiti kako su izlučena tri faktora. U tablici 7. navedene su pripadajuće varijable pokazatelja korištenja informacijsko-komunikacijskih tehnologija za 2011. godinu prema tri izlučena faktora kao i vrijednosti pojedinih faktora.

Tablica 7. Prikaz varijabli prema izlučenim faktorima

<i>Faktor 1: Korištenje interneta od strane pojedinaca</i>	
EUP_1: Kupovina sredstava za e-učenje	0.675
EUP_2: Traženje informacija o obrazovanju, obuci i tečajevima	0.835
EUP_3: Korištenje interneta za obuku i obrazovanje	0.905
EUP_4: Korištenje interneta za donošenje odluka o učenju	0.857
EBP_1: Korištenje internetskog bankarstva	0.836
EZP_1: Korištenje interneta za traženje zaposlenja	0.811
EJUP_1: Slanje obrazaca putem stranica javne uprave	0.848
EJUP_2: Komunikacija s organizacijama javne uprave	0.920
<i>Faktor 2: Transfer visokih tehnologija</i>	
EZ_1: Uvoz visokih tehnologija unutar EU27 (% ukupnog uvoza)	0.653
EZ_2: Uvoz visokih tehnologija izvan EU27 (% ukupnog uvoza)	0.881
EZ_3: Uvoz visokih tehnologija u svijetu (% ukupnog uvoza)	0.936
EZ_4: Izvoz visokih tehnologija unutar EU27 (% ukupnog izvoza)	0.896
EZ_5: Izvoz visokih tehnologija izvan EU27 (% ukupnog izvoza)	0.937
EZ_6: Izvoz visokih tehnologija u svijetu (% ukupnog izvoza)	0.968
<i>Faktor 3: Elektroničko poslovanje tvrtki</i>	
EPT_1: Korištenje CRM softvera	0.849
EPT_2: Kupovina putem interneta	0.790
EPT_3: Naručivanje putem interneta	0.717

Izvor: Istraživanje autora prema Eurostatu (2014.).

Provođenjem faktorske analize na odabranih 17 varijabli o korištenju informacijsko-komunikacijskih tehnologija izlučena su tri faktora koja se sukladno varijablama koje obuhvaćaju nazivaju: *Faktor 1: Korištenje interneta od strane pojedinaca*, *Faktor 2: Transfer visokih tehnologija* i *Faktor 3: Elektroničko poslovanje tvrtki*. Obilježja svakoga faktora pojedinačno se detaljnije analiziraju u nastavku.

Faktor 1: Korištenje interneta od strane pojedinaca

S obzirom na odabrane varijable prvi faktor, dobiven postupkom faktorske analize, nazvan je *Korištenje interneta od strane pojedinaca*. Unutar *Faktora 1* nalazi se osam varijabli koje se odnose na korištenje informacijsko-komunikacijskih tehnologija od strane pojedinaca za obavljanje privatnih aktivnosti, kao što su: EUP_1: Kupovina sredstava za e-učenje, EUP_2: Traženje informacija o obrazovanju, obuci i tečajevima, EUP_3: Korištenje interneta za obuku i obrazovanje, EUP_4: Korištenje interneta za donošenje odluka o učenju, EBP_1: Korištenje internetskog bankarstva, EZP_1: Korištenje interneta za traženje zaposlenja, EJUP_1: Slanje obrazaca putem stranica javne uprave, EJUP_2: Komunikacija s organizacijama javne uprave (tablica 7).

Tablica 8. Pokazatelji korištenja informacijsko-komunikacijskih tehnologija uključenih u Faktor 1: Korištenje interneta od strane pojedinaca; 2011. godina

Varijable / Zemlje	EUP_1	EUP_2	EUP_3	EUP_4	EBP_1	EZP_1	EJUP_1	EJUP_2
Prosjek	13,8	29,7	39,2	33,3	40,3	17,4	16,2	34,3
St. dev.	11,9	10,8	16,2	16,3	25,1	6,9	13,0	19,2
Austrija	23	39	35	27	44	21	12	39
Belgija	11	22	39	31	54	14	13	32
Bugarska	1	22	13	5	3	12	6	15
Cipar	4	15	23	22	20	7	9	22
Češka Republika	6	12	22	21	30	7	4	17
Danska	28	45	64	56	75	27	50	72
Estonija	5	34	33	26	68	25	35	48
Finska	24	34	70	67	79	27	28	58
Francuska	15	20	51	47	51	15	16	36
Grčka	4	20	28	24	9	13	4	13
Hrvatska	4	31	28	21	20	20	5	16
Irska	15	38	44	35	33	20	19	27
Island	24	54	75	71	80	26	50	77
Italija	5	21	38	35	20	12	5	17
Latvija	2	30	42	39	53	27	8	31
Litva	3	24	25	20	41	14	16	22
Luksemburg	43	45	72	65	59	15	15	55
Mađarska	10	33	33	30	21	20	14	28
Makedonija	1	12	17	11	4	11	2	12
Malta	16	39	43	38	42	20	10	28
Nizozemska	30	31	38	19	79	19	35	59
Norveška	30	42	63	57	85	30	34	68
Njemačka	29	36	38	29	45	18	13	37
Poljska	10	17	35	33	27	11	7	21
Portugal	5	33	42	39	22	11	17	23
Rumunjska	3	25	20	17	4	9	4	7
Slovačka	10	25	27	21	34	18	12	35
Slovenija	10	33	47	42	31	14	9	40
Španjolska	6	43	39	29	28	17	12	32
Švedska	33	34	50	44	78	26	32	62
Turska	1	10	18	14	6	4	3	9
Ujedinjeno Kraljevstvo	32	32	42	29	45	26	18	40

Izvor: Istraživanje autora prema Eurostatu (2014.).

Napomena: Sivo označene vrijednosti veće su od prosječne vrijednosti svih zemalja uključenih u analizu.

Unutar tablice 8. nalaze se europske zemlje koje su se koristile u analizi te su istaknute zemlje čiji stanovnici više od europskoga prosjeka koriste informacijsko-komunikacijske tehnologije u osobne svrhe prema varijablama iz *Faktora 1*. Korištenje i razvoj informacijsko-komunikacijskih tehnologija uvelike je povezano sa stupnjem ekonomskoga i društvenoga razvoja zemalja. Može se zaključiti kako se stanovnici razvijenih europskih zemalja više koriste informacijsko-komunikacijskim tehnologijama uz nekoliko iznimki. Belgija, Italija i Španjolska se ističu samo u jednoj varijabli, dok su u preostalim sedam varijabli ispod europskoga prosjeka. U Estoniji, koja pripada u skupinu zemalja u razvoju, stanovnici se u velikom broju koriste informacijsko-komunikacijskim tehnologijama prilikom obavljanja financijskih usluga, traženja zaposlenja, korištenja usluga javne uprave i za traženje informacija o obrazovanju. Osim Estonije, ističu se i Litva, Latvija i Malta, ali jedino u korištenju informacijsko-komunikacijskih tehnologija za obrazovanje, traženje zaposlenja i provođenje bankarskih usluga, dok su daleko ispod prosjeka s obzirom na korištenje usluga javne uprave putem interneta. Zemlje u razvoju počele su uvelike poticati razvoj i implementaciju informacijsko-komunikacijskih tehnologija, što se vidi na primjeru Estonije, Litve, Latvije i Malte čiji stanovnici u velikom broju koriste internet.

Faktor 2: Transfer visokih tehnologija

S obzirom na odabrane varijable drugi faktor, dobiven postupkom faktorske analize, nazvan je *Transfer visokih tehnologija*. Unutar *Faktora 2* nalazi se šest varijabli koje se odnose na aktivnosti tvrtki s obzirom na transfer visokih tehnologija unutar i izvan EU27 zemalja i u svijetu: EZ_1: Uvoz visokih tehnologija unutar EU27 (% ukupnog uvoza), EZ_2: Uvoz visokih tehnologija izvan EU27 (% ukupnog uvoza), EZ_3: Uvoz visokih tehnologija u svijetu (% ukupnog uvoza), EZ_4: Izvoz visokih tehnologija unutar EU27 (% ukupnog izvoza), EZ_5: Izvoz visokih tehnologija izvan EU27 (% ukupnog izvoza) i EZ_6: Izvoz visokih tehnologija u svijetu (% ukupnog izvoza) (tablica 7.).

Unutar tablice 9. nalaze se europske zemlje koje su se koristile u analizi te su istaknute zemlje unutar kojih tvrtke više od europskoga prosjeka uvoze i/ili izvoze visoke tehnologije. Vrijednosti transfera visokih tehnologija za sve varijable su za tri razvijene zemlje: Ujedinjeno Kraljevstvo, Njemačka i Irska uvelike veće od prosječne vrijednosti svih zemalja uključenih u analizu. Osim razvijenih europskih zemalja, ističu se i zemlje u razvoju, kao što su: Češka Republika, Estonija, Mađarska i Malta, koje uvelike sudjeluju u uvozu i/ili izvozu visokih tehnologija, jer su uvidjele prednosti koje razvoj i implementacija informacijsko-komunikacijskih tehnologija ima na poslovanje tvrtki. Vrijednosti za sve navedene zemlje, osim Estonije, u svih šest varijabli koje se nalaze unutar *Faktora 3* su veće od prosječne vrijednosti svih zemalja uključenih u analizu. Estonija ima nešto slabiju vrijednost jedino za varijablu EZ_5: Izvoz visokih tehnologija izvan EU27.

Tablica 9. Pokazatelji korištenja informacijsko-komunikacijskih tehnologija uključenih u Faktor 2: Transfer visokih tehnologija; 2011. godina

Varijable / Zemlje	EZ_1	EZ_2	EZ_3	EZ_4	EZ_5	EZ_6
Prosjek	10,9	15,4	12,3	9,2	14,1	10,8
St. dev.	6,8	11,7	7,3	6,4	11,8	7,7
Austrija	8,5	17,1	10,5	9,3	15,6	11,2
Belgija	6,9	9,1	7,6	7,0	9,7	7,7
Bugarska	9,8	4,9	7,8	3,8	3,7	3,8
Cipar	7,7	7,6	7,7	17,0	10,3	14,9
Češka Republika	12,6	31,4	17,4	15,4	20,2	16,2
Danska	12,3	8,8	11,3	7,3	13,2	9,3
Estonija	13,7	19,5	15,0	16,2	12,2	14,9
Finska	10,6	8,8	9,9	5,7	10,8	8,0
Francuska	12,8	14,9	13,5	14,3	25,5	18,6
Grčka	11,7	3,9	8,0	5,1	3,3	4,2
Hrvatska	5,8	10,3	7,6	5,4	6,5	5,8
Irska	12,6	32,2	18,6	16,0	27,3	20,7
Island	6,6	6,3	6,5	0,7	4,7	1,6
Italija	10,6	8,3	9,5	5,5	7,7	6,4
Latvija	7,9	9,6	8,3	5,0	10,0	6,7
Litva	7,0	2,0	4,8	6,6	4,1	5,6
Luksemburg	7,8	57,1	17,0	21,8	37,6	24,8
Mađarska	12,4	33,0	18,7	16,0	36,2	20,8
Makedonija	4,9	8,0	6,3	3,7	1,6	2,9
Malta	17,1	31,5	20,9	13,8	41,4	30,1
Nizozemska	8,8	24,8	17,4	17,4	17,1	17,3
Norveška	9,5	17,4	12,2	2,6	9,7	4,0
Njemačka	12,1	17,4	14,1	12,5	14,8	13,4
Poljska	9,4	12,2	10,3	4,9	6,4	5,2
Portugal	7,9	5,3	7,2	2,0	5,7	3,0
Rumunjska	9,9	13,2	10,8	8,6	10,1	9,1
Slovačka	9,4	16,8	11,4	6,7	5,9	6,6
Slovenija	6,7	6,7	6,7	4,0	8,4	5,3
Španjolska	10,0	5,4	8,0	4,4	5,5	4,8
Švedska	13,8	14,9	14,1	9,8	19,1	13,9
Turska	8,4	8,8	8,7	0,9	2,2	1,6
Ujedinjeno Kraljevstvo	45	26	45	26	45	26

Izvor: Istraživanje autora prema Eurostatu (2014.).

Napomena: Sivo su označene vrijednosti veće od prosječne vrijednosti svih zemalja uključenih u analizu.

Faktor 3: Elektroničko poslovanje tvrtki

S obzirom na odabrane varijable treći, posljednji, faktor, dobiven postupkom faktorske analize, nazvan je *Elektroničko poslovanje tvrtki*. Unutar *Faktora 3* nalazi se najmanji broj varijabli, samo tri varijable, koje se odnose na korištenje informacijsko-komunikacijskih tehnologija od strane tvrtki prilikom obavljanja poslovnih aktivnosti: EPT_1: Korištenje CRM softvera, EPT_2: Kupovina putem interneta i EPT_3: Naručivanje putem interneta.

Unutar tablice 10. nalaze se europske zemlje koje su se koristile u analizi te su istaknute zemlje u kojima tvrtke više od europskoga prosjeka koriste informacijsko-komunikacijske tehnologije prema varijablama iz *Faktora 3*. Implementacija i korištenje informacijsko-komunikacijskih tehnologija u poslovanju uvelike je povezana sa stupnjem ekonomskoga i društvenoga razvoja zemalja. Prema podacima iz tablice 10. moguće je zaključiti kako tvrtke razvijenih europskih zemalja više koriste informacijsko-komunikacijske tehnologije uz nekoliko iznimki. Francuska i Španjolska ističu se samo u jednoj varijabli (EPT_1: Korištenje CRM softvera), kao i Island i Portugal (EPT_3: Naručivanje putem interneta), dok su vrijednosti za preostale dvije varijable niže od prosječne vrijednosti svih zemalja uključenih u analizu. Estonija, koja se u prethodna dva faktora, isticala kao zemlja u kojoj se uvelike potiče razvoj i korištenje informacijsko-komunikacijskih tehnologija, u ovom slučaju je daleko ispod europskoga prosjeka. Potrebno je istaknuti zemlje u razvoju, kao što su Češka Republika, Malta i Litva, čije tvrtke značajno koriste informacijsko-komunikacijske tehnologije te koje značajno napreduju u odnosu na ostale zemlje u razvoju. Navedene zemlje uvidjele su kako prednosti informacijsko-komunikacijskih tehnologija mogu doprinijeti njihovome gospodarskom razvoju i daljnjem napretku te uvelike potiču njihovo korištenje.

Tablica 10. Pokazatelji korištenja informacijsko-komunikacijskih tehnologija uključenih u *Faktor 3: Elektroničko poslovanje tvrtki*; 2011. godina

Varijable / Zemlje	EPT_1	EPT_2	EPT_3
Prosjek	18,3	23,8	14,1
St. dev.	5,1	15,5	7,2
Austrija	29	41	11
Belgija	24	51	22
Bugarska	13	6	3
Cipar	19	1	7
Češka Republika	17	39	26
Danska	21	48	23
Estonija	10	17	11
Finska	27	33	17
Francuska	19	20	11
Grčka	18	6	6
Hrvatska	13	0	18
Irska	26	49	23
Island	16	22	16
Italija	17	11	4
Latvija	13	14	9

Nastavak tablice 10.

Varijable / Zemlje	EPT_1	EPT_2	EPT_3
Litva	14	27	21
Luksemburg	18	32	15
Mađarska	7	18	10
Makedonija	14	4	3
Malta	19	22	16
Nizozemska	20	28	19
Norveška	24	51	31
Njemačka	23	40	20
Poljska	13	12	8
Portugal	18	14	16
Rumunjska	13	9	4
Slovačka	20	15	13
Slovenija	15	18	11
Španjolska	21	20	11
Švedska	25	38	24
Turska	21	11	8
Ujedinjeno Kraljevstvo	17	44	15

Izvor: Istraživanje autora prema Eurostatu (2014.).

Napomena: Sivo su označene vrijednosti veće od prosječne vrijednosti svih zemalja uključenih u analizu.

6. ZAKLJUČAK

Informacijsko-komunikacijske tehnologije imaju pozitivan utjecaj na društveni i ekonomski razvoj zemalja. Najkonkurentnije zemlje svijeta su ujedno one čiji stanovnici u velikoj mjeri koriste informacijsko-komunikacijske tehnologije, čije tvrtke ulažu u razvoj i implementaciju informacijsko-komunikacijskih tehnologija i u kojima se potiče korištenje informacijsko-komunikacijskih tehnologija u obrazovanju. Upravo, zbog brojnih prednosti prilikom korištenja informacijsko-komunikacijskih tehnologija važno je utvrditi i način mjerenja njihova utjecaja na društveni i ekonomski razvoj zemalja. Brojni su pokazatelji i studije kojima je moguće mjeriti korištenje informacijsko-komunikacijskih tehnologija i njihov utjecaj na razvoj društva i gospodarstva.

Cilj ovoga rada je prikazati veliki broj pokazatelja korištenja informacijsko-komunikacijskih tehnologija te kako od prikupljenog većeg broja pokazatelja podijeljenih unutar pet područja utvrditi manji broj osnovnih grupa odabranih varijabli. Primijenjena je faktorska analiza na odabranih 17 varijabli te su izlučena tri faktora. Unutar *Faktora 1: Korištenje interneta od strane pojedinaca* nalazi se najveći broj varijabli, osam varijabli, koje se odnose na korištenje interneta od strane pojedinaca za obrazovanje, za kupovinu knjiga, za provođenje financijskih transakcija, za traženje zaposlenja, za korištenje usluga javne uprave. Unutar *Faktora 2: Transfer visokih tehnologija* nalazi se šest varijabli koje se odnose na aktivnosti tvrtki s obzirom na uvoz i izvoz visokih tehnologija unutar i izvan

EU27 zemalja i u svijetu. *Faktor 3: Elektroničko poslovanje tvrtki* sastoji se od najmanjega broja varijabli, samo tri varijable, i definira aktivnosti tvrtki na internetu, kao što su naručivanje putem interneta, kupovina putem interneta i korištenje CRM softvera za ostvarivanje boljega odnosa s klijentima.

Budući da su izlučena tri faktora, koja se međusobno razlikuju s obzirom na subjekt aktivnosti korištenja informacijsko-komunikacijskih tehnologija, može se zaključiti kako je cilj faktorske analize ostvaren. Također, s početnih pet područja i 17 varijabli, provedenom faktorskom analizom izlučena su tri faktora. Dva područja (aktivnosti tvrtki na internetu i e-znanost – uvoz i izvoz visokih tehnologija), podudaraju se s dva izlučena faktora: *Faktor 3: Elektroničko poslovanje tvrtki* i *Faktor 2: Transfer visokih tehnologija*. Tri područja (e-učenje namijenjeno pojedincima, aktivnosti pojedinaca na internetu i e-javna uprava (pojedinci)), koja se odnose na korištenje interneta od strane pojedinaca za obrazovanje, obavljanje financijskih usluga, traženje zaposlenja i korištenje usluga javne uprave grupirana su unutar *Faktora 1: Korištenje interneta od strane pojedinaca*.

Budući da su rezultati testirani na podacima o korištenju informacijsko-komunikacijskih tehnologija za 2011. godinu, preporuka za daljnja istraživanja jest proširiti istraživanje tako da se u analizu uključe dodatne varijable kao i podaci za dodatne godine. Na taj način unaprijedila bi se kvaliteta istraživačke tematike, a mogao bi se utvrditi i tijek daljnjega razvoja i korištenja informacijsko-komunikacijskih tehnologija unutar europskih zemalja.

LITERATURA:

1. Akman, I., Mishra, A. (2010). Gender, Age and Income Differences in Internet Usage among Employees in Organizations. *Computers in Human Behavior*, 26(3), 482-490.
2. Anttiroiko, A. V. (2001). Toward the European Information Society. *Communications of the ACM*, 44(1), 31-35.
3. Bartholomew, D. J., Steele F., Moustaki I., Galbraith, J. I. (2008). *Analysis of Multivariate Social Science Data*, 2nd ed. Boca Raton, USA: CRC press.
4. Bilbao-Osorio, B., Dutta, S., Lanvin, B. (2013). The Global Information Technology Report 2013 - Growth and Jobs in a Hyperconnected World. Geneva: World Economic Forum. Dostupno na: http://www3.weforum.org/docs/WEF_GITR_Report_2013.pdf Pregledano [25. 5. 2014.].
5. Blackman, C. (2004). Stumbling along or Grave New World? Towards Europe's Information Society. *Foresight*, 6(5), 261-270.
6. Cilan, C. A., Bolat, B. A., Coskun, E. (2009). Analyzing Digital Divide Within and Between Member and Candidate Countries of European Union. *Government Information Quarterly*, 26(1), 98-105.
7. Dünnebeil, S., Sunyaev, A., Blohm, I., Leimeister, J. M., Kremer, H. (2012). Determinants of Physicians' Technology Acceptance for E-Health in Ambulatory Care. *International Journal of Medical Informatics*, 81(11), 746-760.
8. European Commission Database - Eurostat (2014). Dostupno na: http://epp.eurostat.ec.europa.eu/portal/page/portal/statistics/search_database [2. 3. 2014.].

9. Gu, J.-W., Jung, H.-W. (2013). The Effects of IS Resources, Capabilities, and Qualities on Organizational Performance: An Integrated Approach. *Information and Management*, 50, 87-97.
10. Hair, J. F., Black B., Babin, B., Anderson, R. E., Tatham, R. L. (2005). *Multivariate Data Analysis*, 6th ed. New Jersey: Prentice Hall.
11. International Telecommunication Union (2013). Measuring the Information Society. Dostupno na: http://www.itu.int/en/ITU-D/Statistics/Documents/publications/mis2013/MIS2013-exec-sum_E.pdf. Pregledano [25. 4. 2014.].
12. Katz, R., Koutroumpis, P., Callorda, F. M. (2014). Using a Digitization Index to Measure the Economic and Social Impact of Digital Agendas. *info* 16(1), 32-44.
13. Khalil, O. E. M. (2011). E-Government Readiness: Does National Culture Matter? *Government Information Quarterly*, 28(3), 388-399.
14. Lee, Y., Lee, H. (2011). Application of Factor Analysis for Service R&D Classification: A Case Study on the Korean ICT Industry. *Expert Systems with Applications*, 38, 2119-2124.
15. Lehner, B. S., Jung, J., Stieler, Lorenz, B., Nitzsche, A., Driller, E., Wasem, J., Pfaff, H. (2013). Psychosocial Factors in the Information and Communication Technology Sector. *Management Decision*, 51(9), 1878-1892.
16. Misuraca, G., Codagnone, C., Rossel, P. (2013). From Practice to Theory and back to Practice: Reflexivity in Measurement and Evaluation for Evidence-Based Policy Making in the Information Society. *Government Information Quarterly*, 30, S68-S82.
17. Panian, Ž. (ur.) (2005.). *Informatički enciklopedijski rječnik*. Zagreb: Europapress holding.
18. Shareef, M. A., Kumar, V., Kumar, U., Dwivedi, Y. K. (2011). E-Government Adoption Model (GAM): Differing Service Maturity Levels. *Government Information Quarterly*, 28(1), 17-35.
19. Tambe, P., Hitt, L. M. (2012). Now IT's Personal: Offshoring and the Shifting Skill Composition of the U.S. Information Technology Workforce. *Management Science*, 58(4), 678-695.