

Usvajanje tehnologija velikih podataka u pametnim gradovima Europske Unije: Analiza važnosti i performansi tehnoloških čimbenika

Jasmina Pivar

Sveučilište u Zagrebu Ekonomski fakultet

Sažetak

Gradovi Europske Unije na svom razvoju prema pametnom gradu usvajaju tehnologije velikih podataka. S obzirom na to da su tehnologije velikih podataka složene i disruptivne tehnologije, potrebno je utvrditi važnost čimbenika i njihovih aspekata za usvajanje tehnologija velikih podataka u gradovima. Cilj rada je identificirati najvažnije aspekte tehnoloških čimbenika usvajanja tehnologija velikih podataka u gradovima Europske Unije. Kako bi se ostvario cilj rada provedeno je istraživanje na uzorku gradova Europske Unije, a na prikupljenim podacima provedena je analiza mape važnosti i performansi čimbenika usvajanja tehnologija velikih podataka. Rezultati istraživanja pokazuju da su aspekti apsorpcijskog kapaciteta i tehnološke spremnosti gradova EU relativno visoke važnosti, no uz niske razine performansi u odnosu na čimbenike organizacije i okoline. Doprinos rada sastoji se od općih smjernica za povećanje razine tehnološke spremnosti i apsorpcijskog kapaciteta gradova kako bi se povećala uspješnost usvajanja tehnologija velikih podataka u gradovima Europske Unije.

Ključne riječi: pametni gradovi, Europska Unija, usvajanje tehnologija, tehnologije velikih podataka, apsorpcijski kapacitet, tehnološka spremnost, IPMA

Vrsta rada: znanstveni rad

Primljeno: 11.12.2020.

Prihvaćeno: 8.1.2021.

Uvod

U pametnim gradovima značajno mjesto zauzima informacijska i komunikacijska tehnologija. Informacijski i procesni pogled na gradove pametne gradove opisuje kao „sophisticirane sustave u kojima se u realnom vremenu obrađuje velika količina podataka te integrira u procese, sustave, organizacije i vrijednosne lance s ciljem optimizacije operacija i informiranja nadležnih o problemima“ (Neirotti, 2014). Usvajanje tehnologija treba polaziti od potreba građana, ostalih dionika i javnih problema koje je potrebno riješiti pa tako tehnologije neće biti korištene na jednak način u svim gradovima. Stoga se u svrhu ovog rada pametnim gradom smatra onaj koji "nastoji riješiti javne probleme pomoću rješenja temeljenih na informacijskim i komunikacijskim tehnologijama uz zajedničku podršku više dionika i lokalne vlasti" (Odbor Europskog parlamenta za industriju, istraživanje i energetiku, 2014). Dakle, odabir i primjena informacijske i komunikacijske tehnologije u određenom gradu ovisi o njegovim potrebama i okruženju.

Tehnologije velikih podataka splet su informacijskih i komunikacijskih tehnologija za stvaranje, usvajanje, pohranu, obradu i analizu velikih količina podataka. Mogu se smatrati inovativnim informacijskim i komunikacijskim tehnologijama s obzirom na to da su u mnogim gradovima u procesu usvajanja ili su u potpunosti nove i razmatra se njihovo usvajanje. Poduzeća u zemljama Europske Unije u velikoj mjeri su počela koristiti velike podatke za potrebe pametnog poslovanja (Pejić Bach et al., 2020). Veliki podaci često su dio inicijativa digitalne transformacije poslovanja (Tomičić Furjan, Tomičić-Pupek i Pihir, 2020). U velikim se podacima pronalaze znanja i informacije koje služe pri donošenju odluka, a pritom je moguće koristiti različite metode i tehnike analize podataka poput rudarenja teksta (Pejić Bach et al., 2019) i različitih novih metoda za predviđanje (Pejić Bach, Pivar i Krstić, 2019). Tehnologije velikih podataka u gradovima se koriste za poboljšanje različitih područja grada (Hashem, 2016; Bettencourt, 2013). One omogućavaju primjenu različitih pametnih rješenja na različitim područjima infrastrukture grada. Kako bi se postigli željeni učinci usvajanja informacijskih i komunikacijskih tehnologija u gradu, menadžment grada i dionici trebaju zajedno aktivno upravljati te sudjelovati u razvoju pametnog grada (Bolívar, 2015). Međutim, usvajanje složenih tehnologija kao što su tehnologije velikih podataka predstavlja izazov za gradove zbog čega je važno znati koji su čimbenici važni za njihovo usvajanje u gradu te koje su trenutne performanse važnih čimbenika.

Cilj rada je odgovoriti na pitanje koji su to aspekti tehnoloških čimbenika važni za usvajanje tehnologija velikih podataka u gradovima Europske Unije. Kako bi se ostvario cilj rada, prikupljeni su podaci anketnim istraživanjem na uzorku gradova Europske Unije. Na prikupljenim podacima, prvo je provedena procjena glavnog modela istraživanja korištenjem metode modeliranja strukturnih jednadžbi parcijalnih najmanjih kvadrata (engl. Partial Least Squares Structural Equation Modelling – PLS-SEM). Nakon procjene PLS-SEM provedena je analiza mapa važnosti i performansi (engl. Importance-Performance Map Analysis – IPMA) kako bi se usporedile važnosti i performanse neovisnih tehnoloških čimbenika te njihovih

aspekata za usvajanje tehnologija velikih podataka u gradovima Europske Unije. Rad je nastavak istraživanja provedenog u svrhu doktorske disertacije u kojem se procjenjuje model usvajanja tehnologija velikih podataka u gradovima Europske Unije (Pivar, 2020a). S obzirom na to da se IPMA temelji na rezultatima procjene modela, ovaj rad sadrži sažetak ključnih rezultate procjene modela iz navedene doktorske disertacije. Istraživanje je nadopuna postojećih istraživanja o čimbenicima organizacije i okoline usvajanja tehnologija velikih podataka u gradovima EU (Pivar i Vlahović, 2020; Pivar, 2020b). Doprinos rada ogleda se u objašnjenju važnosti i performansi tehnoloških čimbenika usvajanja tehnologija velikih podataka u gradovima Europske Unije, budući da su dosadašnja istraživanja promatrala čimbenike usvajanja velikih podataka ili analitike velikih podataka na razini organizacije (Cegielski, Jia i Hall, 2018; Lai, Sun i Ren, 2018; Chen, Preston i Swink, 2015).

Rad nakon Uvoda sadrži Pregled literature i razvoj hipoteza u kojem je opisan model na koji se oslanja ovaj rad te su objašnjeni tehnološki čimbenici. Nakon toga su u poglavlju Metodologija opisani istraživački instrument, podaci te metoda analize važnosti i performansi. Poglavlje Rezultati sadrži rezultate mjerne i strukturne procjene glavnog modela, a potom rezultate analize važnosti i performansi. Na kraju slijede Diskusija i Zaključak.

Pregled literature i razvoj hipoteza

Postojeća tehnološka infrastruktura značajno utječe na difuziju tehnologije u organizaciji (Tornatzky, Fleischer i Chakrabarti, 1990). Tehnološku infrastrukturu organizacije čini postojeći računalni hardver, softver i mrežne tehnologije organizacije potrebne za implementaciju novih informacijskih i komunikacijskih tehnologija (Bhattacharjee i Hikmet, 2008). Čimbenikom tehnološke spremnosti mogu se uz tehnološku infrastrukturu obuhvatiti i IT ljudski resursi (Zhu, Kraemer i Xu, 2006) te tehnološke kompetencije kao dio organizacijskog kapaciteta za inovacije temeljene na informacijskim tehnologijama (Sambamurthy, Bharadwaj i Grover, 2003). Organizacije će vjerojatnije usvojiti inovativne informacijske i komunikacijske tehnologije ako imaju razvijene aspekte tehnološke spremnosti (Wang i Lo, 2016; Dedrick et al., 2015).

Organizacijska spremnost utječe na odluku o usvajanju inovacije (Tsai i Tang, 2012). Pojam organizacijske spremnosti objedinjuje percepciju menadžmenta o stupnju svjesnosti o novim informacijskim i komunikacijskim tehnologijama, posjedovanja resursa i upravljačkih sposobnosti te predanosti organizacije koji su potrebni za usvajanje inovativnih informacijskih i komunikacijskih tehnologija (Tan, Tyler i Manica, 2007). Organizacijska spremnost uz tehnološku spremnost obuhvaća i financijsku spremnost koju čine financijski resursi potrebni za investiranje u nove tehnologije (Rouhani et al., 2018).

U svrhu istraživanja tehnološka spremnost opisana je kroz tehnološku infrastrukturu, tehnološku ekspertizu i financijske resurse te je postavljena hipoteza H1a:

H1a: Tehnološka spremnost statistički značajno pozitivno utječe na usvajanje tehnologija velikih podataka u gradovima.

Apsorpcijski kapacitet prvotno je korišten kako bi se opisala društvena sposobnost zemalja u razvoju, no na razini organizacije, apsorpcijski kapacitet opisuje sposobnost usvajanja novog znanja koja ovisi o apsorpcijskom kapacitetu članova organizacije (Cohen i Levinthal, 1990).

Usvajanje tehnologije velikih podataka kao rizične disruptivne inovacije zahtijeva apsorpcijski kapacitet grada za raspoznavanje potencijalne vrijednosti uvođenja tehnologija velikih podataka u infrastrukturu grada. Apsorpcijski kapacitet grada je određen iskustvima grada stečenim prijašnjim usvajanjem različitih informacijskih i komunikacijskih tehnologija. Iako je apsorpcijski kapacitet korišten u različitim kontekstima i na različitim razinama analize postoji tek nekoliko istraživanja u kojima su neki od aspekata apsorpcijskog kapaciteta korišteni u modelima usvajanja informacijskih i komunikacijskih tehnologija, na primjer u Rouhani et al. (2018) te Weia, Lowry i Seedorf (2015). Apsorpcijski kapacitet je za potrebe glavnog istraživanja sveden na razinu grada i podrazumijeva sposobnost grada da prepozna vrijednost novih, vanjskih znanja, asimilira ih i koristi u različite svrhe. Hipoteza koja pretpostavlja direktan pozitivan utjecaj apsorpcijskog kapaciteta na usvajanje tehnologija velikih podataka u gradovima glasi:

H1b: Apsorpcijski kapacitet statistički značajno pozitivno utječe na usvajanje tehnologija velikih podataka u gradovima.

Prema teoriji difuzije inovacija, kompatibilnost je stupanj u kojem je inovacija percipirana konzistentnom sa postojećim vrijednostima, prošlim iskustvima i potrebom potencijalnih usvajača (Rogers, 2003). Organizacije koje percipiraju tehnologiju kompatibilnijom sa postojećim vjerovanjima i radnim praksama, imaju veće predispozicije za uspješno usvajanje novih tehnologija.

Kompatibilnost je korištena u modelima usvajanja različitih tehnologija u različitim djelatnostima, no istraživanja su pokazala da je ona značajan čimbenik u ponekim primjerima usvajanja računalstva u oblacima (Gutierrez, Boukrami i Lumsden, 2015; Abdollahzadehgan et al., 2013) i RFID tehnologija (Wang, Wang i Jang, 2010). U svrhu ovog istraživanja kompatibilnost velikih podataka definirana je kao stupanj u kojem se tehnologije velikih podataka percipiraju konzistentnima sa postojećom infrastrukturom, praksama i potrebama grada. Hipoteza glavnog modela istraživanja vezana za utjecaj kompatibilnosti na usvajanje tehnologija velikih podataka u gradovima glasi:

H1c: Kompatibilnost statistički značajno pozitivno utječe na usvajanje tehnologija velikih podataka u gradovima

Metodologija

U ovom poglavlju objašnjena je metodologija korištena za provedbu glavnog istraživanja, a potom metoda analize važnosti i performansi korištena da bi se ispunio cilj rada.

Model usvajanja tehnologija velikih podataka u gradovima Europske Unije

Ovo istraživanje temelji se na analizi rezultata procjene šireg istraživačkog modela usvajanja tehnologija velikih podataka u gradovima Europske Unije. Model je temeljen na okviru Tehnologija-Organizacija-Okolina (engl. The Technology-Organization-Environment Framework - TOE). Okvir TOE razvili su Tornatzky, Fleischer i Chakrabarti (1990) s ciljem objašnjenja procesa usvajanja inovacije u poslovanju organizacija. Prema TOE okviru na usvajanje određene inovativne informacijske i komunikacijske tehnologije utječe specifičan splet čimbenika tehnologije, organizacije i okoline.

TOE okvir primjenjuje se za objašnjenje usvajanja brojnih inovativnih informacijskih i komunikacijskih tehnologija stoga je TOE okvir bio temelj za konceptualizaciju modela usvajanja tehnologija velikih podataka u gradovima Europske Unije. Za potrebe istraživanja, ovisni čimbenik istraživačkog modela naziva se Usvajanje tehnologija velikih podataka u gradovima (UT) i opisan je kao proces prihvaćanja, integracije i korištenja tehnologija velikih podataka u gradovima. Fokus ovog istraživanja su neovisni čimbenici tehnološkog konteksta Apsorpcijski kapacitet (AK), Tehnološka spremnost (TS) i Kompatibilnost (KM). U glavnom istraživanju postavljene su hipoteze o direktnom pozitivnom utjecaju tehnoloških čimbenika na usvajanje tehnologija velikih podataka u gradovima Europske Unije. Pretpostavljeno je da tehnološka spremnost pozitivno utječe na usvajanje tehnologija velikih podataka u gradovima (H1a), kao i apsorpcijski kapacitet (H1b) te kompatibilnost (H1c).

Dodatni neovisni čimbenici šireg istraživačkog modela su organizacijski čimbenici Postojanje strategije pametnog grada (PMG) i Podrška menadžmenta grada (PMG) te Podrška dionika (PD) kao čimbenik okoline. Iako čimbenici organizacije i okoline nisu u fokusu, potrebno ih je uključiti u rezultate procjene glavnog modela te ih koristiti za usporedbu sa tehnološkim čimbenicima.

Istraživački instrument

Prikupljanje podataka za procjenu glavnog istraživačkog modela provedeno je pomoću strukturiranog anketnog upitnika. Čestice korištene u upitniku su stvorene ili prilagođene temeljem postojeće literature. Svaki čimbenik mjeran je korištenjem četiri čestice Likertovom skalom na intervalu od jedan do sedam.

Upitnik je podijeljen na 4 dijela. U prvom dijelu mjerene su čestice tehnoloških čimbenika. Čestice za mjerenje tehnološke spremnosti (TS) samostalno su definirane,

dok su čestice za mjerenje apsorpcijskog kapaciteta preuzete i prilagođene prema Flatten et al. (2011), a čestice za mjerenje kompatibilnosti su prilagođene prema Gangwar, Date i Ramaswamy (2013) te Chong i Chan (2012). U drugom dijelu mjereni su organizacijski čimbenici. Čestice za mjerenje podrške menadžmenta grada preuzete su i prilagođene prema Oliveira, Manoj i Espadanal (2014) i ITU-T Focus Group on Smart Sustainable Cities (2015), dok su čestice za mjerenje postojanja strategije pametnog grada razvijene prema pregledu karakteristika strategije pametnog grada (Angelidou, 2014). U trećem dijelu upitnika mjerena je podrška dionika kao čimbenik okoline za što su razvijene čestice prema pregledu dionika pametnog grada (ITU-T Focus Group on Smart Sustainable Cities, 2015). U prvom dijelu mjeren je ovisni čimbenik usvajanje tehnologija velikih podataka u gradovima Europske Unije za koji su čestice samostalno definirane. Detalji istraživačkog instrumenta prikazani su u Tablici 1.

Tablica 1
Istraživački instrument

Čimbenici	Čestice	Tvrdnja	
Neovisni čimbenici	Kod	Molimo vas da označite do koje mjere se slažete/ne slažete sa sljedećim tvrdnjama. (1 = u potpunosti se ne slažem, 7 = u potpunosti se slažem)	
Tehnologija	Tehnološka spremnost (TS)	TS1	Grad zapošljava ljudske potencijale s analitičkim vještinama.
		TS2	Grad zapošljava ljudske potencijale s informatičkim vještinama i vještinama korištenja programskih jezika, tehnologija i programa vezanih uz velike podatke.
		TS3	Grad posjeduje fizičku IKT infrastrukturu koja se može nadograditi trenutnim tehnologijama velikih podataka i povezanim tehnologijama.
		TS4	Menadžment grada je svjestan troškova i koristi od investicija u tehnologije te raspolaže financijskim sredstvima za nadogradnju grada tehnologijama.
	Apsorpcijski kapacitet (AK)	AK1	Zaposlenici grada motivirani su za korištenje dostupnih izvora podataka vezanih uz usluge koje grad trenutno pruža.
		AK2	Odjeli grada svjesni su važnosti međusobne pomoći pri rješavanju problema te među njima postoji brz protok informacija.
		AK3	Zaposlenici grada apsorbiraju nova znanja, povezuju postojeća znanja sa novim spoznajama, koriste ih u praktičnom radu i čine raspoloživim za korištenje u budućnosti.
		AK4	U gradu postoji svijest o novim tehnologijama te ih se redovito razmatra i usvaja kako bi gradske usluge bile učinkovitije.
	Kompatibilnost (KM)	KM1	Tehnologije VP kompatibilne su sa postojećom tehnološkom infrastrukturom grada i mogu se nesmetano uklopiti u postojeću teh. infrastrukturu grada.
		KM2	Promjene koje donosi razvoj tehnologija VP konzistentne su sa postojećim praksama i iskustvima grada sa implementacijom sličnih tehnologija.
		KM3	Promjene i koristi koje donosi implementacija tehnologija VP konzistentne su sa potrebama grada.
		KM4	Tehnologije VP kompatibilne su sa postojećom infrastrukturom, praksama i potrebama grada.
Organizacija	Podrška menadžmenta grada (PMG)	PMG1	Menadžment grada pruža snažno vodstvo i posvećen je procesima usvajanja tehnologija u gradu.
		PMG2	... promiče tehnološke inicijative, određuje korake implementacije i odabire specifična tehnološka rješenja koje će se implementirati.
		PMG3	... spreman je prihvatiti financijske i organizacijske rizike vezane uz usvajanje tehnologija.
		PMG4	... uključuje građane u napore vezane uz tehnološke inovacije i prema njima komunicira o koristima tehnologije.
	Postojanje strategije pametnog grada (SPG)	SPG1	Temeljem izazova vezanih uz gradsku infrastrukturu i potreba grada menadžment grada aktivno razvija strategije s ciljem poboljšanja učinkovitosti upravljanja gradskim resursima.
		SPG2	Strategija grada usmjerena je na učinkovitost i tehnološki napredak "tvrde" infrastrukture grada.
		SPG3	... usmjerena je na učinkovitost i tehnološki napredak "meke" infrastrukture grada.

	SPG4	Strategija grada usklađena je sa ciljevima i strategijom zemlje i/ili Europske Unije vezane uz tehnološki razvoj gradova.
Okolina Podrška dionika	PD1	Postoje dionici koji omogućuju tehnologiju i tehnološka rješenja vezane uz usvajanje tehnologija u gradu.
	PD2	Postoje dionici koji su zainteresirani za pokretanje inicijativa usvajanja tehnologija u gradu.
	PD3	Građani i građanske organizacije podržavaju ili sudjeluju u inicijativama usvajanja tehnologija u gradu.
	PD4	Postoje institucionalizirani dionici koji osiguravaju sredstva, pomoć i okvire za usvajanje tehnologija u gradovima.
Ovisni čimbenici		
Usvajanje tehnologija velikih podataka u gradovima (UT)	UT1	Grad prikuplja velike količine strukturiranih, polustrukturiranih i nestrukturiranih podataka iz različitih izvora.
	UT2	Grad je usvojio infrastrukturu i platforme potrebne za otkrivanje znanja iz VP.
	UT3	Grad je usvojio tehnologije VP s ciljem poboljšanja "tvrde" infrastrukture grada.
	UT4	Grad je usvojio tehnologije VP s ciljem poboljšanja "meke" infrastrukture grada.

Izvor: Flatten et al. (2011); Gangwar et al. (2013); Chong i Chan (2012); Oliveira, Manoj i Espadanal (2014); ITU-T Focus Group on Smart Sustainable Cities (2015); Angelidou (2015) i prilagođeno prema Pivar (2020a)

Podaci

S ciljem prikupljanja podataka koji su bili temelj procjene modela istraživanja provedeno je anketno istraživanje u razdoblju od lipnja 2017. godine do ožujka 2018. godine.

Ciljana populacija istraživanja su gradovi zemalja članica Europske Unije (EU28). Istraživanje je obuhvatilo gradove s 40 tisuća i više stanovnika. Ciljanu populaciju činilo je ukupno 1481 gradova. Ciljani ispitanici istraživanja bili su članovi višeg menadžmenta u gradu, uključujući gradonačelnike, menadžere informatičkih odjela grada, glavne informacijske direktore i voditelje inicijativa pametnih gradova. Svakom gradu priključen je jedan ispitanik. Upitnik je uspješno poslan na 1100 gradova. Ukupno je zaprimljeno 110 djelomično ili u potpunosti ispunjenih upitnika, a u svrhu daljnje analize korišten je uzorak podataka prikupljenih od 67 gradova Europske Unije.

Analiza mapa važnosti i performansi

U svrhu procjene glavnog modela istraživanja korištena je metoda modeliranja strukturnih jednadžbi parcijalnih najmanjih kvadrata (engl. Partial Least Squares Structural Equation Modelling – PLS-SEM) uz podršku SmartPLS3 softvera. SEM - PLS je korišten u nizu istraživanja gdje se provelo ispitivanje modela usvajanja različitih tehnologija temeljenih na TOE okviru. Procjena glavnog modela provedena je prema koracima procjene PLS-SEM modela predloženima u Hair et al. (2017).

Nakon procjene PLS-SEM modela moguće je provesti analizu mapa važnosti i performansi (engl. Importance-Performance Map Analysis – IPMA). Metoda IPMA uspoređuje važnost i performanse neovisnih čimbenika te njihovih pokazatelja u predviđanju ciljanog ovisnog čimbenika. Provedba procjene glavnog modela nužan je

preduvjet za provedbu IPMA-e zato što se u njoj koriste rezultati procjene mjernog i strukturnog modela istraživanja.

Važnosti čimbenika u PLS-SEM modelima predstavljene su vrijednostima ukupnih efekata koju čine direktni i indirektni efekti na ciljani čimbenik te se kreću u rasponu od - 1 do +1. Što je vrijednost važnosti bliže jedan veća je i važnost čimbenika. Ukoliko čimbenik ima samo direktan utjecaj na ciljani čimbenik, kao u ovom radu, tada su važnosti neovisnih čimbenika jednake njihovim direktnim efektima. Drugim riječima, važnosti čimbenika u tom su slučaju jednake *path* koeficijentima.

Vrijednosti performansi čimbenika i pokazatelja izračunavaju se temeljem vrijednosti njihovih čestica. Izračun započinje izračunom skaliranih vrijednosti svih čestica za svaku od opservacija. Skaliranje opservacije *j* prema čestici *i* izračunava se kao:

Jednadžba 1

Skaliranje opservacije *j* prema čestici *i*

$$x_{ij}^{\text{skalirani}} = \frac{E[x_{ij}] - \min[x_i]}{\max[x_i] - \min[x_i]} \times 100$$

Izvor: prema Hair et al. (2018, str. 110)

gdje je x_i *i*-ta čestica u PLS modelu, $E[x_{ij}]$ je stvarna vrijednost koju je za *i*-tu česticu dodijelio ispitanik *j*, a $\min[]$ i $\max[]$ su minimalna i maksimalna vrijednost koju može poprimiti neka čestica (Hair et al., 2018, str. 110). Na primjer, ako su čestice mjerene Likertovom skalom na rasponu od 1 do 7 tada je minimalna vrijednost 1, a maksimalna 7. Vrijednost koju skalirana vrijednost može poprimiti je u rasponu od 0 do 100.

Prema Hair et al. (2018) izračunate skalirane vrijednosti čestica po opservacijama koriste se za izračun skaliranih vrijednosti čimbenika koje predstavljaju performanse čimbenika, ali i za izračun performansi čestica. Izračun performansi čestica računa se kao sredina izračunatih skaliranih vrijednosti čestica za sve opservacije, a skalirane vrijednosti čimbenika računaju se kao linearna kombinacija skaliranih vrijednosti čestica i skaliranih vanjskih težina čestica. Što su izračunate vrijednosti više to su veće performanse čimbenika, odnosno čestica.

Nadalje, vrijednosti važnosti čestica određenog čimbenika računaju se množenjem skaliranih vrijednosti vanjskih težina čestica sa ukupnim učinkom kojeg taj čimbenik ima na ciljani čimbenik.

Cilj IPMA-e je identificirati čimbenike koji imaju relativno visoku važnost u predviđanju ciljnog čimbenika, a istovremeno imaju i relativno niske performanse, što znači da u njima postoji mogućnost za poboljšanje. Istraživač može temeljem tumačenja mape važnosti i performansi dati konkretne preporuke za poboljšanje pojedinih aspekata

čimbenika koji mogu povećati performanse ciljnih čimbenika. Slijedom toga, ako se pokaže da pojedini tehnološki čimbenici imaju visoku važnost za usvajanje tehnologija velikih podataka u gradovima, ali su na niskim relativnim razinama performansi moguće je provesti dublju analizu njihovih aspekata koje je potrebno poboljšati.

U svrhu ovog istraživanja IPMA je korištena na dvije razine: i) razini čimbenika - za identificiranje jesu li tehnološki čimbenici važni za usvajanje tehnologija velikih podataka u gradovima Europske Unije i kakve performanse imaju te ii) razina čestica - za identificiranje koji aspekti tehnoloških čimbenika imaju relativno visoku važnost, a niže performanse, odnosno imaju potencijala za poboljšanje kroz različite aktivnosti te tako pozitivno utjecati na uspješnost usvajanja tehnologija velikih podataka u gradovima Europske Unije.

Procedura IPMA-e provedena je prema koracima predloženima u Ringle i Stardsted (2016) i Hair et al. (2018). IPMA je korištena u dosadašnjim istraživanjima za identificiranje aspekata čimbenika važnih za usvajanje različitih tehnologija i koncepata, poput računalstva u oblaku (Khayer et al., 2020), mobilnog učenja (Al-Emran i Mezhuyev, 2020), elektroničkog poslovanja (Nathan et al. 2019.; Magal, Kosalgei Levenburg, 2009), bolničkog informacijskog sustava (Markazi-Maghaddam, Kazemi i Alimoradnori, 2019) i kriptovaluta (Sohaib et al., 2020).

Rezultati

Rezultati procjene modela usvajanja tehnologija velikih podataka u gradovima Europske Unije

Rezultati mjerne i strukturne procjene modela usvajanja tehnologija velikih podataka u gradovima Europske Unije dio su objavljene doktorske disertacije (Pivar, 2020a). Za potrebe ovog rada rezultati procjene modela su sažeti.

Rezultati procjene mjere reflektivnih čimbenika prije i nakon rješavanja problema mjernog modela prikazani su u Tablici 2. Temeljem pokazatelja Cronbach Alfa za procjenu pouzdanosti unutarnje konzistentnosti čimbenika zaključuje se kako je pouzdanost i valjanost svih čimbenika zadovoljavajuća. Naime, vrijednosti pokazatelja Cronbach Alfa nalaze se unutar dozvoljenih granica za sve reflektivno mjerene čimbenike, a vrijednost pokazatelja prosječno objašnjene varijance za sve njih je veća od 0,500. Prema Fornell - Larcker kriteriju u modelu ne postoji problem diskriminantne valjanosti s obzirom na to da je vrijednost kvadratnog korijena AVE svakog čimbenika veća od njegove najveće korelacije sa bilo kojim drugim čimbenikom.

Čestica TS3 ima vanjsko opterećenje manje od 0,700 stoga je donesena je odluka o njegovu izbacivanju iz čimbenika TS. Čestica TS3 govori o slaganju ispitanika da grad posjeduje fizičku IKT infrastrukturu koja se može nadograditi tehnologijama velikih podataka. Međutim, taj je aspekt već obuhvaćen u određenoj mjeri u čimbeniku

modela koji opisuje kompatibilnost tehnološke infrastrukture grada stoga ga je moguće isključiti iz modela.

Tablica 2

Rezultati procjene mjernog modela reflektivnih čimbenika

Čimbenik	Čestice	Cronbach Alfa	Prosječno objašnjena varijanca-AVE	Vanjska opterećenja	Fornell-Larcker
		>0,600	>0,500	>0,700	$\sqrt{AVE} > CORR$
TS	TS1	0,813/ 0,810*	0,877/ 0,726**	0,866/0,884***	da
	TS2			0,883/0,879***	
	TS3			0,674/ izbačen	
	TS4			0,766/0,790***	
KM	KM1	0,887	0,747	0,824	da
	KM2			0,910	
	KM3			0,776	
	KM4			0,937	
PMG	PMG1	0,913	0,794	0,882	da
	PMG2			0,938	
	PMG3			0,880	
	PMG4			0,863	
SPG	SPG1	0,908	0,784	0,879	da
	SPG2			0,887	
	SPG3			0,890	
	SPG4			0,885	
PD	PD1	0,801	0,625	0,763	da
	PD2			0,746	
	PD3			0,848	
	PD4			0,800	

*vrijednost Cronbach Alfa nakon rješavanja problema mjernog modela

** vrijednost AVE nakon rješavanja problema mjernog modela

***vrijednost vanjskih opterećenja nakon rješavanja problema mjernog modela

Izvor: prema Pivar (2020a), uz pomoć softvera SmartPLS3 i Office 2019

Rezultati procjene formativnih čimbenika prije i nakon rješavanja problema mjernog modela prikazani su u Tablici 3.

Vanjske težine čestica čimbenika Apsorpcijski kapacitet – AK1 i AK2 nisu značajne, ali su apsolutno važne s obzirom na to da im je vanjsko opterećenje veće od minimalno potrebne vrijednosti od 0,500. Vanjska težina čestice UT1 čimbenika Usvajanje tehnologija velikih podataka u gradovima nije ni apsolutno ni relativno važna za procjenu usvajanja tehnologije velikih podataka u gradovima. Drugim riječima, prikupljanje velikih količina podataka ne mora nužno značiti da grad usvaja tehnologije velikih podataka. Iz tog razloga, donesena je odluka o njenom izbacivanju iz čimbenika UT.

Prema vrijednosti varijance inflacijskog faktora - VIF za formativne čimbenike ne postoji problem kolinearnosti.

Tablica 3

Rezultati procjene mjernog modela formativnih čimbenika

Čimbenik	Čestica	Vanjska težina	p-vrij.	Vanjsko opterećenje >0,500	Važnost čestice	VIF <5,000
AK	AK1	0,019/ 0,005 ⁱ	0,918/ 0,979 ⁱⁱ	0,761/ 0,754 ⁱⁱⁱ	apsolutna	2,706
	AK2	-0,028/ -0,026 ⁱ	0,923/ 0,927 ⁱⁱ	0,798/ 0,797 ⁱⁱⁱ	apsolutna	3,050
	AK3	0,637/ 0,644 ⁱ	0,017/ 0,015 ⁱⁱ	0,932/ 0,931 ⁱⁱⁱ	apsolutna i relativna	3,168
	AK4	0,477/ 0,482 ⁱ	0,011/ /0,007 ⁱⁱ	0,868/ 0,869 ⁱⁱⁱ	apsolutna i relativna	2,256
UT	UT1	-0,020/ n/a ⁱ	0,833/ n/a ⁱⁱ	0,443/ n/a ⁱⁱⁱ	izbačen	1,311 / n/a ^{iv}
	UT2	0,540/ 0,517 ⁱ	0,000/ 0,000 ⁱⁱ	0,942/ 0,939 ⁱⁱⁱ	apsolutna i relativna	2,815 / 2,518 ^{iv}
	UT3	0,258/ 0,269 ⁱ	0,043/ 0,034 ⁱⁱ	0,895/ 0,899 ⁱⁱⁱ	apsolutna i relativna	3,440 / 3,431 ^{iv}
	UT4	0,299/ 0,302 ⁱ	0,016/ 0,016 ⁱⁱ	0,900/ 0,902 ⁱⁱⁱ	apsolutna i relativna	3,364 / 3,357 ^{iv}

ⁱ vanjska težina nakon rješavanja problema mjernog modelaⁱⁱ p-vrijednost nakon rješavanja problema mjernog modelaⁱⁱⁱ vanjsko opterećenje nakon rješavanja problema mjernog modela^{iv} VIF nakon rješavanja problema mjernog modela

Izvor: prema Pivar (2020a), uz pomoć softvera SmartPLS3 i Office 2019

U tablici 4 prikazani su rezultati procjene strukturnog modela. Uz razinu pouzdanosti 10% dokazano je da tehnološki čimbenici apsorpcijski kapacitet (AK→UT, *path* koeficijent 0,216, p-vrijednost 0,069) i tehnološka spremnost (TS→UT, *path* koeficijent 0,191, p-vrijednost 0,052) pozitivno utječu na usvajanje tehnologije velikih podataka u gradovima.

Prema vrijednostima koeficijenta determinacije i prilagođenog koeficijenta determinacije predloženi čimbenici usvajanja tehnologija velikih podataka u gradovima objašnjavaju zadovoljavajuću količinu varijance usvajanja tehnologija velikih podataka u gradovima.

Tablica 4

Rezultati procjene strukturnog modela

Utjecaj	Path koeficijent	p.-vrij.
AK→UT	0,216	0,069***
TS→UT	0,191	0,052***
KM→UT	-0,131	0,132
PD→UT	0,271	0,000*
PMG→UT	0,184	0,085***
SPG→UT	0,279	0,012**
R ²	0,791	
Prilagođeni R ²	0,770	

*statistički signifikantno uz 1%

**statistički signifikantno uz 5%

***statistički signifikantno uz 10%

Izvor: prema Pivar (2020a), uz pomoć softvera SmartPLS3 i Office 2019

Rezultati analize važnosti i performansi

Preduvjet za analizu važnosti i performansi tehnološki čimbenika jest dokazivanje hipoteza modela usvajanja tehnologija velikih podataka u gradovima Europske Unije. Hipoteze H1a i H1b su podržane, odnosno pokazalo se da apsorpcijski kapacitet i tehnološka spremnost pozitivno utječu na usvajanje tehnologije velikih podataka u gradovima. Kompatibilnost nema značajan utjecaj na usvajanje tehnologije velikih podataka u gradovima stoga je ispuštena iz daljnje interpretacije rezultata analize.

Analiza važnost i performansi na razini čimbenika

U nastavku su prikazani rezultati IPMA-e. Sve vrijednosti izračunate su uz podršku specijaliziranog softvera SmartPLS3. U Tablici 7 nalaze se vrijednosti važnosti i performansi čimbenika za koje se pokazalo da značajno utječu na ciljani čimbenik UT. Prosjek važnosti i performansi izračunat je kako bi se na mapu važnosti i performansi mogla ucrtati linije za podjelu mape na 4 segmenta.

Tablica 5

Vrijednosti važnosti i performansi čimbenika usvajanja tehnologija velikih podataka u gradovima Europske Unije (N=67)

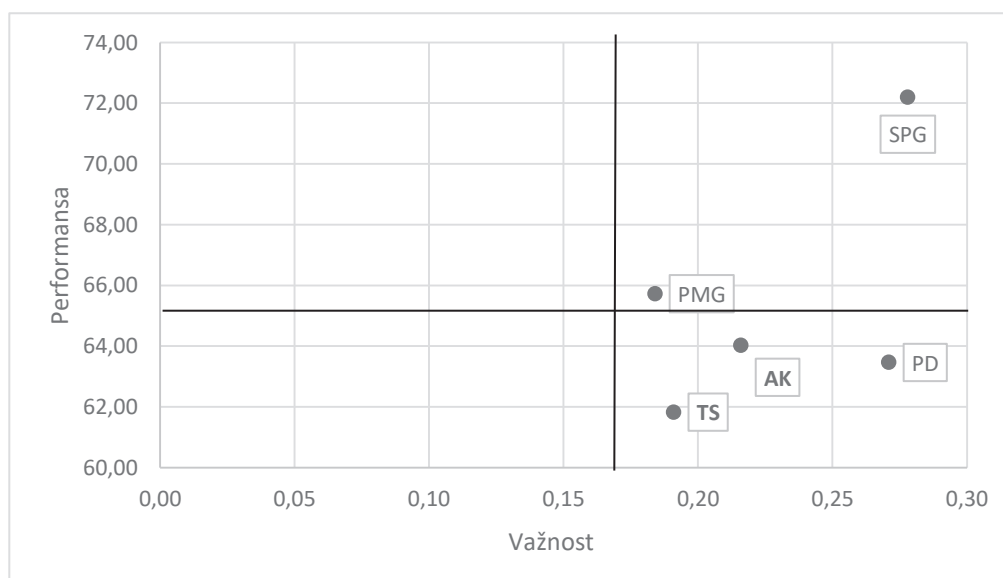
Čimbenik	Važnost	Performanse
AK	0,216	64,034
TS	0,191	61,833
KM	-0,131	57,672
PMG	0,184	65,733
SPG	0,278	72,201
PD	0,271	63,468
Prosjek	0,168	64,157

Izvor: autorica, uz pomoć softvera SmartPLS3 i Office 2019

Mapa važnosti i performansi čimbenika (Slika 1) prikazuje vrijednosti ukupnih efekata, odnosno važnosti čimbenika koji ukazuju da najvišu važnost za performanse usvajanja tehnologija velikih podataka u gradovima ima postojanje strategije pametnog grada. Mape sugeriraju da podrška dionika ima najviše potencijala za poboljšanjem i utjecajem na usvajanja tehnologija velikih podataka. Naime, podrška dionika ima relativno niske performanse, ali vrlo visoki ukupni učinak na usvajanje tehnologija velikih podataka u gradovima Europske Unije. Kada govorimo o tehnološkim čimbenicima, gradovi mogu razmišljati o tome kako poboljšati apsorpcijski kapacitet grada i tehnološke spremnosti s ciljem podrške usvajanju tehnologija velikih podataka u gradovima. Pritom je vidljivo da su oba čimbenika relativno niskih performansi, dok je važnost apsorpcijskog kapaciteta relativno veća od tehnološke spremnosti. Jačanjem oba čimbenika povećala bi se uspješnost, odnosno performanse usvajanja tehnologija velikih podataka u gradovima Europske Unije.

Slika 1

Mapa važnosti i performansi čimbenika usvajanja tehnologija velikih podataka u gradovima Europske Unije



Izvor: autorica, uz pomoć softvera SmartPLS3 i Office 2019

Analiza važnost i performansi na razini čestica

Tablica 8 prikazuje vrijednosti važnosti i performansi čestica svih čimbenika. U nastavku će se za potrebe interpretacije rezultata IPMA-e čestice nazivati aspektima čimbenika. Izračunat je i prosjek važnosti i performansi kako bi se na mapu važnosti i performansi mogla ucrtati linije za podjelu mape na 4 segmenta.

Tablica 6

Vrijednosti važnosti i performansi aspekata čimbenika usvajanja tehnologija velikih podataka u gradovima Europske Unije (N=67)

Aspekt	Važnost	Performanse
AK1	0,001	66,915
AK2	-0,006	66,169
AK3	0,139	61,194
AK4	0,104	67,910
TS1	0,079	55,970
TS2	0,073	61,443
TS4	0,072	67,164
KM1	-0,033	55,970
KM2	-0,041	54,975
KM3	-0,027	64,677
KM4	-0,048	57,214
PMG1	0,050	72,886
PMG2	0,052	68,657
PMG3	0,054	58,955
PMG4	0,051	61,940
SPG1	0,075	74,876
SPG2	0,075	72,139
SPG3	0,082	71,891
SPG4	0,082	70,149
PD1	0,100	66,418
PD2	0,069	65,174
PD3	0,097	60,199
PD4	0,077	61,940
Prosjek	0,044	64,794

Izvor: autorica, uz pomoć softvera SmartPLS3 i Office 2019

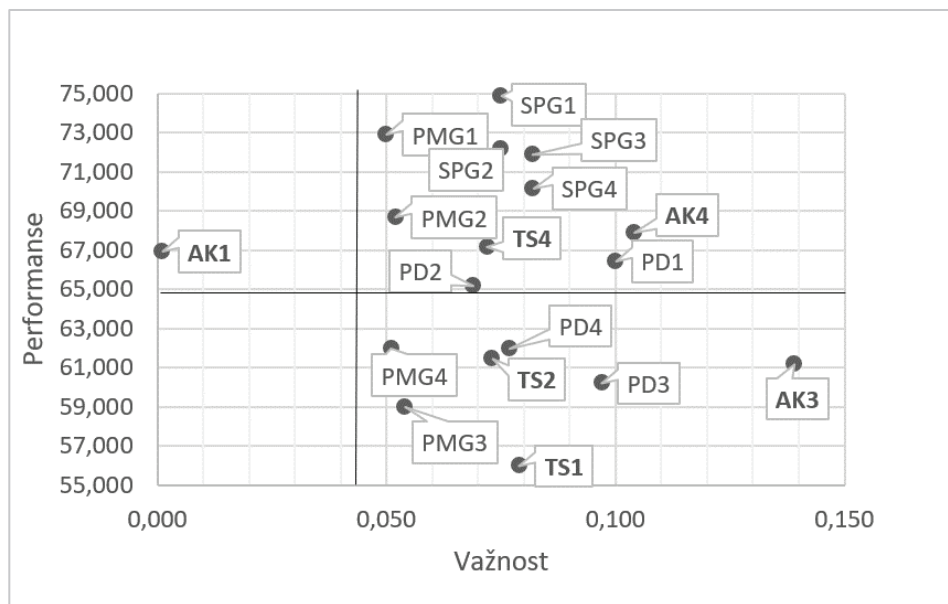
Mapa važnosti i performansi čestica (Slika 2) sugerira da najviše potencijala za poboljšanjem usvajanja tehnologija velikih podataka u pametnim gradovima od tehnoloških čimbenika imaju aspekti AK3, TS1 i TS2.

Od tehnoloških čimbenika, najveći potencijal za poboljšanjem ima aspekt apsorpcije znanja od strane zaposlenika (AK3). Navedeno znači da usvajanje tehnologija velikih podataka u gradovima Europske Unije može biti uspješnije ako zaposlenici grada povećaju apsorpciju novih znanja, povežu postojeća znanja sa novim spoznajama, koriste takva znanja u praktičnom radu i čine ih raspoloživim za korištenje u budućnosti. Grad može pozitivno utjecati na usvajanje tehnologija velikih podataka u gradu kroz jačanje aspekta TS1 koji opisuje analitičke vještine zaposlenika. To bi značilo da gradovi trebaju težiti zapošljavanju ljudskih potencijala koje posjeduju analitičke vještine, uključujući vještine rudarenja podataka i znanje o metodologiji obrade podataka, integraciji podataka te upravljanju podacima. Također, grad bi trebao zaposliti osobe koje posjeduju informatičke vještine i vještine korištenja

programskih jezika, tehnologija i programa poput Excela, SAS-a, SPSS-a, programskog jezika R, Java, alata za vizualizaciju, SQL baze podataka, noSQL baze podataka i Hadoop rješenja, koje su sastavni dio tehnologija velikih podataka (aspekt TS2).

Slika 2

Mapa važnosti i performansi aspekata čimbenika usvajanja tehnologija velikih podataka u gradovima Europske Unije



Izvor: autorica, uz pomoć softvera SmartPLS3 i Office 2019

Diskusija

Nalazi istraživanja pokazali su da su tehnološka spremnost grada i apsorpcijski kapacitet grada važni za usvajanje tehnologija velikih podataka u gradovima. Postojeća istraživanja u skladu su sa tim nalazima. Organizacije koje imaju razvijene aspekte tehnološke spremnosti uspješnije usvajaju različite informacijske i komunikacijske tehnologije važne za razvoj pametnih gradova, na primjer sustave poslovne inteligencije i upravljanja znanjem (Bhatiasevi i Naglis, 2020; Lautenbach, Johnston i Adeniran Ogundipe, 2017), računalstva u oblaku (Hassan et al., 2017, Hossain, Standing i Chan, 2017) te Interneta stvari (Ching-Wen i Ching-Chiang, 2017). Također, apsorpcijski kapacitet pozitivno utječe na usvajanje informacijskih i komunikacijskih tehnologija kao što je RFID tehnologija koja je važna za pametne gradove (Weia, Lowry i Seedorf, 2015). Utjecaj kompatibilnosti na usvajanje tehnologija velikih podataka nije dokazan. Navedeno je u skladu s ponekim istraživanjima u kojima se ona promatrala u kontekstu nekih drugih tehnologija poput RFID tehnologije (Thiesse et al., 2011) i računalstva u oblaku (Gutierrez, Boukrami i Lumsden, 2015).

Važan dio tehnološke spremnosti grada je svjesnost menadžment grada o troškovima i koristima od investicija u tehnologije te raspoloživim financijskim resursima. Grad je tehnološki spreman ukoliko je ispunjen i financijski aspekt raspolaganja financijskim resursima za nadogradnju grada informacijskim i komunikacijskim tehnologijama. Ovi su aspekti tehnološke spremnosti grada prema analizi važnosti i performansi relativno važni, ali i na relativno visokim performansama.

Apsorpcijski kapacitet prosječnog grada Europske Unije je na niskoj razini. Odjeli grada često nisu svjesni važnosti međusobne komunikacije pri rješavanju problema vezanih uz usluge i infrastrukturu grada te važnosti brzog međusobnog protoka informacija. Zaposlenici grada teško apsorbiraju nova znanja vezana uz nove tehnologije i slabo ih povezuju sa postojećim znanjima. Samim time ih u manjoj mjeri koriste u praktičnom radu. Ipak, u gradu postoji svijest o postojanju novih tehnologija te se razmatra njihovo uvođenje za potrebe povećanja učinkovitosti usluga grada. Preporuka je da u gradu razmisle kako motivirati zaposlenike i poboljšati apsorpcijski kapacitet grada s ciljem podrške usvajanju tehnologija velikih podataka u gradovima.

Menadžment grada mogao bi podržati jačanje apsorpcijskog kapaciteta svog grada kroz povećanje razine tehnološke spremnosti grada. Naime, prosječan grad Europske Unije grad u manjoj mjeri ima zaposlenike s analitičkim i informatičkim vještinama koje uključuje vještine upravljanja podacima. Zapošljavanjem ljudskih potencijala koje posjeduju vještine upravljanja podacima povećao bi se i apsorpcijski kapacitet grada za usvajanjem naprednih informacijskih i komunikacijskih tehnologija kao što je tehnologija velikih podataka.

Prema pristupu Sustava upravljanja kvalitetom moguće je stvoriti okvir programa razvoja pametnog grada. Primjer okvira programa za razvoj pametnih gradova predstavljen je i objašnjen u Borsboom-van Beurden, Kallaos, Gindroz, Costa i Riegler (2016). Prema navedenom okviru razvoj pametnog grada prolazi kroz faze definiranja vizije, osiguranja političke predanosti svih dionika, planiranja provedbe aktivnosti, ostvarenja planova, praćenja i procjene uspješnosti provedbe planova, djelovanja na rezultate procjene te naposljetku na repliciranje i ponovnu primjenu dobrih praksi. Tehnološki čimbenici se stoga mogu povezati s fazama okvira programa za razvoj pametnih gradova, odnosno rezultate analize je moguće približiti menadžmentu grada i ostalima gradovima pomoću poznatog koncepta kontinuiranog poboljšanja i sustava upravljanja kvalitetom.

Opća je preporuka da gradovi ovisno o tome u kojoj su fazi razvoja pametnog grada obrate posebnu pozornost na pojedine faze okvira programa razvoja pametnog grada.

Gradovi koji tek kreću prema razvoju pametnog grada trebaju za početak posebnu pozornost posvetiti fazama stvaranja vizije, političke predanosti i planiranja. Navedene su faze važne za postizanje više razine zrelosti pametnog grada s obzirom da osiguravaju preduvjete i povoljne razine čimbenika za usvajanje naprednih informacijskih i komunikacijskih tehnologija kao što su tehnologije velikih podataka. Dakle, gradovi koji su tek na početku razvoja pametnog grada moraju osigurati

povoljne uvjete za provođenje pametnih inicijativa, pa tako i usvajanje inovativnih informacijskih i komunikacijskih tehnologija. Među njima je i postizanje zadovoljavajuća razine tehnoloških preduvjeta, odnosno tehnološke spremnosti i apsorpcijskog kapaciteta grada.

Pametni gradovi koji nisu usvojili tehnologiju velikih podataka mogu se temeljem praćenja i procjena stanja infrastrukture usmjeriti planiranju projekata usvajanja tehnologija velikih podataka. Pretpostavka je da su oni za potrebe postojećih projekata osigurali određenu razinu tehnoloških čimbenika. Međutim, važno je posebno ojačati apsorpcijski kapacitet i tehnološku spremnost grada kako bi se mogle usvojiti tehnologije velikih podataka.

Gradovi usvajači tehnologija velikih podataka u pravilu imaju visoku razinu apsorpcijskog kapaciteta i tehnološke spremnosti. Oni trebaju pratiti i procijeniti utjecaj usvajanja tehnologija velikih podataka na gradove i prema potrebi prilagoditi planove. Gradovi koji su uspješno proveli projekte usvajanja tehnologija velikih podataka u gradovima mogu diseminirati svoje znanje i pružiti dobar primjer ostalim gradovima. Za njih su moguća fina podešavanja aspekata tehnološke spremnosti i apsorpcijskog kapaciteta za buduća potencijalna usvajanje različitih inovativnih informacijskih komunikacijskih tehnologija povezanih sa tehnologijama velikih podataka.

Dakle, preporuka gradovima je da na početku svog razvoja prema pametnom gradu procjenjuju i osiguraju nužne aspekte tehnološke spremnosti i apsorpcijskog kapaciteta. Tehnološku spremnost i apsorpcijski kapacitet potrebno je kroz kasnije faze kontinuirano poboljšavati kako bi se postigla viša razina zrelosti pametnog grada. Na taj će način grad ostvariti preduvjete i osigurati uspješnost usvajanja tehnologija velikih podataka.

Zaključak

U ovom istraživanju identificirani su važni tehnološki čimbenici i njihovi aspekti za usvajanje tehnologija velikih podataka u gradovima Europske Unije. Kako bi se mogla analizirati važnost i performansa pojedinog čimbenika za usvajanje tehnologija velikih podataka u gradovima Europske Unije bilo je potrebno provesti procjenu glavnog istraživačkog modela usvajanja tehnologija velikih podataka u gradovima Europske Unije. Rezultati procjene istraživačkog modela temelj su analize provedene u svrhu ovog rada. Model je procijenjen temeljem podataka prikupljenih anketnim upitnikom na uzorku gradova Europske Unije. Rezultati istraživanja pokazuju da apsorpcijski kapacitet i tehnološka spremnost gradova utječu na usvajanje tehnologija velikih podataka u gradovima, no njihove postojeće performanse za prosječan europski grad su niskih performansi. U radu su dane opće smjernice za povećanje razine tehnološke spremnosti i apsorpcijskog kapaciteta gradova s ciljem povećanja uspješnosti usvajanja tehnologija velikih podataka u gradovima Europske Unije. Na taj je način ispunjen cilj istraživanja.

Znanstveni doprinos ovog rada ogleda se u primjeni metode PLS-SEM i IPMA-e za objašnjenje usvajanja tehnologija velikih podataka u gradovima Europske Unije. Praktični doprinos ogleda se u općim preporukama gradovima vezano za značajne tehnološke čimbenike.

Ograničenje ovog istraživanja je općenitost preporuka za gradove koji nisu na istim razinama zrelosti pametnog grada. Kako bi se prevladalo ovo ograničenje potrebno je uvesti kategorije gradova prema zrelosti pametnog grada te potom za svaku kategoriju grada dati preporuke kojim čimbenicima i aspektima čimbenika je potrebno posvetiti pozornost te pokrenuti aktivnosti kako bi se povećala uspješnost usvajanja tehnologija u gradovima. U budućim istraživanjima potrebno je objediniti nalaze analize važnosti i performansi sa nalazima vezanim uz čimbenike organizacije i okoline.

Reference:

Abdollahzadehgan, A. et al. (2013). The Organizational Critical Success Factors for Adopting Cloud Computing in SMEs. *Journal of information systems research and innovation*, 67-64.

Al-Emran M., Mezhuyev V. (2020) Examining the Effect of Knowledge Management Factors on Mobile Learning Adoption Through the Use of Importance-Performance Map Analysis (IPMA). U: Hassanien A., Shaalan K., Tolba M. (Eds.), *Proceedings of the International Conference on Advanced Intelligent Systems and Informatics 2019. AISI 2019. Advances in Intelligent Systems and Computing, vol 1058*. (str. 449-458). Springer, Cham.

Angelidou, M. (2014). Smart city policies: A spatial approach. *Cities*, 41, 3-11.

Bettencourt, L.M.A. (2014). The Uses of Big Data in Cities. *Mary Ann Liebert, INC.*, 2(1), 1-11.

Bhatiasevi, V., Naglis, M. (2020). Elucidating the determinants of business intelligence adoption and organizational performance. *Information Development*, 36(1), 78-96.

Bhattacharjee, A., Hikmet, N. (2008). Reconceptualizing organizational support Reconceptualizing Organizational Support and its Effect on Information Technology Usage: Evidence from the Health Care Sector. *Journal of Computer Information Systems*, 48(4), 69-76.

Bolívar, M. P. (2015) Smart Cities: Big Cities, Complex Governance? U: Bolívar, R., Pedro, M., ur. *Transforming City Governments for Successful Smart Cities*. Springer International Publishing, 1-7.

Borsboom-van Beurden et al. (2016). *Smart City Guidance Package – A Roadmap for Integrated Planning and Implementation of Smart City Projects*. EIP-SCC. https://eu-smartcities.eu/sites/default/files/2019-07/Smart%20City%20Guidance%20Package%20LowRes%201v22%20%28002%29_0.pdf

- Cegielski, C.G., Jia, L., Hall, D.J. (2018). Understanding the Factors Affecting the Organizational Adoption of Big Data. *Journal of computer information systems*, 58(3), 193-203.
- Chen, D.Q., Preston, D.S., Swink, M. (2015). How the Use of Big Data Analytics Affects Value Creation in Supply Chain Management. *Journal of Management Information Systems*, 32(4), 4-39.
- Ching-Wen, H., Ching-Chiang, Y. (2017). Understanding the factors affecting the adoption of the Internet of Things. *Technology Analysis & Strategic Management*, 29(9), 1089-1102.
- Chong, A.Y.-L., Chan, F.T.S. (2012). Structural equation modeling for multi-stage analysis on Radio Frequency Identification (RFID) diffusion in the health care industry. *Expert Systems with Applications*, 39(2012), 8645-8654.
- Cohen, W.M., Levinthal D.A. (1990). Absorptive capacity: A new perspective on learning and innovation. *Administrative Science Quarterly*, 35(1), 128-152.
- Dedrick, J. et al. (2015). Adoption of smart grid technologies by electric utilities: factors influencing organizational innovation in a regulated environment. *Electronic Markets*, 25(1), 17-29.
- Flatten, T.C. et al. (2011). *A measure of absorptive capacity: Scale development and validation*. *European Management Journal*, 29(2), 98-116.
- Gangwar, H., Date, H., Ramaswamy, R. (2014). Understanding determinants of cloud computing adoption using an integrated TAM TOE MODEL. *Journal of Enterprise Information Management*, 28 (1), 107-130.
- Gutierrez, A., Boukrami, E., Lumsden, R. (2015). Technological, organisational and environmental factors influencing managers' decision to adopt cloud computing in the UK. *Journal of Enterprise Information Management*, 28 (6), 788-807.
- Hair, J.F. et al. (2017). *A primer on partial least squares structural equation modeling (PLS-SEM)*. Los Angeles, SAD: SAGE Publications.
- Hair, J.F. jr. et al. (2018). *Advanced issues in partial least squares structural equation modelling*. Thousand Oaks, CA: SAGE Publications, Inc.
- Hashem, I. A. T. et al. (2016). The role of big data in smart city. *International Journal of Information Management*, 36, 748-758.
- Hassan, H. et al. (2017). Factors influencing cloud computing adoption in small and medium enterprises. *Journal of Information and Communication Technology (JICT)*, 1, 21-41.
- Hossain, M., Standing, C., Chan, C. (2017). The development and validation of a two-staged adoption model of RFID technology in livestock businesses. *Information Technology & People*, 30(4), 785-808.

- ITU-T Focus Group on Smart Sustainable Cities (2015). *Setting the stage for stakeholders' engagement in smart sustainable cities*. <http://www.itu.int/en/ITU-T/focusgroups/ssc/Pages/default.aspx>[10.prosinca, 2015.]
- Khayer, A., Jahan, N., Hossain, M.N., Hossain, M.Y. (2020). The adoption of cloud computing in small and medium enterprises: a developing country perspective. *VINE Journal of Information and Knowledge Management Systems*, Vol. ahead-of-print No. ahead-of-print. <https://doi.org/10.1108/VJKMS-05-2019-0064>
- Lai, Y.Y., Sun, H.F., Ren, J.F. (2018). Understanding the determinants of big data analytics (BDA) adoption in logistics and supply chain management: An empirical investigation. *International Journal of Logistics Management*, 29(2), 676-703.
- Lautenbach, P., Johnston, K., Adeniran-Ogundipe, T. (2017). Factors influencing business intelligence and analytics usage extent in South African organisations. *South African Journal of Business Management*, 48(3), 23-33.
- Magal, S.R., Kosalge, P., Levenburg, N.M. (2009). Using importance performance analysis to understand and guide e-business decision making in SMEs. *Journal of Enterprise Information Management*, 22(1/2), 137-151.
- Markazi-Moghaddam, N., Kazemi, A., Alimoradnori, M. (2019). Informatics in Medicine Unlocked, 17, 100251. <https://doi.org/10.1016/j.imu.2019.100251>.
- Nathan, R.J., Victor, V., Gan, C.L., Kot, S. (2019). Electronic commerce for home-based businesses in emerging and developed economy. *Eurasian Business Review*, 9, 463-483.
- Neirotti, P. et al. (2014). Current trends in Smart City initiatives: Some stylized facts. *Cities*, 38, 25-36.
- Sohaib, W., Hussain, M., Asif, M., Ahmad, M., Mazzara, M. (2020). A PLS-SEM Neural Network Approach for Understanding Cryptocurrency Adoption. *IEEE Access*, 8, 13138-13150.
- Odbor Europskog parlamenta za industriju, istraživanje i energetiku – ITRE (2014). *Mapping Smart Cities in the EU*. Bruxelles: European Parliament, Directorate General for internal policies. [https://www.europarl.europa.eu/RegData/etudes/etudes/join/2014/507480/IPOL-ITRE_ET\(2014\)507480_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/etudes/join/2014/507480/IPOL-ITRE_ET(2014)507480_EN.pdf)
- Oliveira, T., Manoj, T., Espadanal, M. (2014). Assessing the determinants of cloud computing adoption: An analysis of the manufacturing and services sectors. *Information & Management*, 51(2014), str. 497-510.
- Pejić Bach, M., Bertoncel, T., Meško, M., Suša Vugec, D., Ivančić, L. (2020). Big Data Usage in European Countries: Cluster Analysis Approach. *Data*, 5(1), 25.
- Pejić Bach, M., Krstić, Ž., Seljan, S., Turulja, L. (2019). Text mining for big data analysis in financial sector: A literature review. *Sustainability*, 11(5), 1277.

- Pejić Bach, M., Pivar, J., Krstić, Ž. (2019) Big Data for Prediction: Patent Analysis – Patenting Big Data for Prediction Analysis. U: Strydom, M. J., Strydom, K., Beverley, S. (Ed.), *Big Data Governance and Perspectives in Knowledge Management* (str. 218-240). Hershey Pennsylvania: IGI Global.
- Pivar, J. (2020a). *Model usvajanja tehnologija velikih podataka u pametnim gradovima Europske Unije* (urn:nbn:hr:148:687894). [Disertacija, Sveučilište u Zagrebu, Ekonomski fakultet]. Repozitorij radova Ekonomskog fakulteta Zagreb - REPEFZG.
- Pivar, J. (2020b) City Management Support And Smart City Strategy as Success Factors in Adopting Big Data Technologies for Smart Cities. U: Drezgić, S., Žišković, S., Tomljanović, M. (Eds.), *Smart Governments, Regions and Cities Research monograph – First Edition* (str. 167- 183).
- Pivar, J. i Vlahović, N. (2020) Stakeholder Support as Critical Success Factor in Adopting Big Data Technologies for Smart Cities. U: Skala, K. (Eds.), *Proceedings of the 43rd International Convention on Information and Communication Technology, Electronics and Microelectronics MIPRO 2020* (pp. 2153-2158). Opatija: Croatian Society for Information and Communication Technology, Electronics and Microelectronics – MIPRO.
- Ringle, C.M., Sarstedt, M. (2016). Gain more insight from your PLS-SEM results: The importance-performance map analysis. *Industrial Management & Data Systems*, 116(9), 1865-1886.
- Rogers, E. M. (2003). *Diffusion of Innovations. 5th Edition*. New York: Free Press.
- Rouhani, S. et al. (2018). Business Intelligence Systems Adoption Model; An Empirical Investigation. *Journal of Organizational and End User Computing*, 30(2), 43-70.
- Sambamurthy, V., Bharadwaj, A., Grover, V. (2003). Shaping Agility through Digital Options: Reconceptualizing the Role of Information Technology in Contemporary Firms, *MIS Quarterly*, 27(2), 237-263.
- Tan, J., Tyler, K. i Manica, A. (2007). Business-to-business adoption of e-commerce in China. *Information & Management*, 44 (3), 332-351.
- Thiesse, F. et al. (2011). The rise of the "next-generation bar code": an international RFID adoption study. *Supply Chain Manage.: Int. J.*, 16, 245–328
- Tomičić Furjan, M., Tomičić-Pupek, K., Pihir, I. (2020). Understanding Digital Transformation Initiatives: Case Studies Analysis. *Business Systems Research*, 11(1), 125-141.
- Tornatzky, L.G., Fleischer, M., Chakrabarti, A. K. (1990). *The Processes of Technological Innovation*. Massachusetts: Lexington Books.
- Tsai, W.-C., Tang, L.-L. (2012). A model of the adoption of radio frequency identification technology: The case of logistics service firms. *Journal of Engineering and Technology Management*, 29(1), 131–151.

Wang, Y.-M., Wang, Y.-S., Yang Y.-F. (2010). Understanding the determinants of RFID adoption in the manufacturing industry. *Technological Forecasting & Social Change*, 77(2010), 803-815.

Wang, H.-J., Lo, J. (2016). Adoption of open government data among government agencies. *Government Information Quarterly*, 33(1), 80-88.

Weia, J., Lowry, P.B., Seedorf, S. (2015). The assimilation of RFID technology by Chinese companies: A technology diffusion perspective. *Information & Management*, 52(6), 628-642.

Zhu, K., Kraemer, K.L., Xu, S. (2006). The process of innovation assimilation by firms in different countries: a technology diffusion perspective on e-business. *Manage. Sci.*, 52, 1557-1576.

O autoru

Jasmina Pivar trenutno je zaposlena kao asistentica na Katedri za informatiku Ekonomskog fakulteta – Zagreb. Doktorirala je na području ekonomije na Ekonomskom fakultetu – Zagreb s doktorskom disertacijom naslova „Usvajanje tehnologija velikih podataka u pametnim gradovima Europske Unije“. Diplomski studij završila je na Fakultetu organizacije i informatike u Varaždinu. Glavni istraživački interesi su joj veliki podaci, pametni gradovi, rudarenje podataka, Internet stvari i usvajanje tehnologija. Autoricu se može kontaktirati na jpivar@efzg.hr