

Izvorni znanstveni rad
UDK: 004.6:005.93
Datum primitka članka u uredništvo: 28. 8. 2023.
Datum slanja članka na recenziju: 8. 11. 2023.
Datum prihvatanja članka za objavu: 18. 12. 2023.

Fran Kranjčić, mag. oecc. *

Prof. dr. sc. Jasna Prester **

UPOTREBA TEHNOLOGIJE VELIKIH PODATAKA U UPRAVLJANJU LANCEM OPSKRBE

THE USE OF BIG DATA TECHNOLOGY IN SUPPLY CHAIN MANAGEMENT

SAŽETAK: Na temelju teorije dinamičkih sposobnosti, u ovom se radu provjerava utječe li upotreba velikih podataka na performanse lanca opskrbe. Istraživanje je provedeno na 105 hrvatskih poduzeća kako bi se hijerarhijskom regresijom provela empirijska analiza. Rezultati pokazuju pozitivan, izravan efekt upotrebe velikih podataka na performanse lanca opskrbe. Ovo istraživanje omogućava razumijevanje kako upotrijebiti analizu velikih podataka za poboljšanje performansi lanca opskrbe, kako izgraditi dinamičke sposobnosti i pomoću njih ostvariti bolji konkurentski položaj na tržištu.

KLJUČNE RIJEČI: analiza velikih podataka, učinkovitost lanca opskrbe, empirijsko istraživanje

ABSTRACT: Based on the theory of dynamic capabilities, this paper examines whether the use of big data affects supply chain performance. The research was conducted on 105 Croatian companies in order to perform an empirical analysis using hierarchical regression. The results show a positive direct effect of the use of big data on supply chain performance. This research provides an understanding of how to use big data analysis to improve supply chain performance, thus building dynamic capabilities and using them to achieve a better competitive position in the market.

KEY WORDS: big data analytics, supply chain efficiency, empirical research

JEL klasifikacija: L25, L60, M11, M15

* Fran Kranjčić, mag. oecc., student

** Prof. dr. sc. Jasna Prester, Ekonomski fakultet Sveučilišta u Zagrebu, jprester@efzg.hr

1. UVOD

U proteklom desetljeću veliki podaci postupno su postali važan čimbenik za postizanje konkurentske prednosti i povećanje dobiti (Agarwal i Dhar, 2014; Akter i sur., 2016; Muller i sur., 2018). Analiza velikih podataka (engl. *Big Data Analytics*), definiraju se kao korištenje naprednih tehnologija za analizu velikih podataka da bi se dobile informacije koje mogu pomoći u predviđanju i donošenju ispravnih odluka u svim operativnim procesima među unutarnjim i vanjskim partnerima (Chen i sur., 2015; Mikalef i sur., 2020).

Tijekom godina znanstvenici su shvatili važnost upotrebe velikih podataka, a studije su potvrdile njihov utjecaj na uspješnost poduzeća (Akter i sur., 2016). Međutim, razumijevanje i empirijsko istraživanje specifičnih mehanizama koje njihova analiza može pružiti tek je u začetku u odnosu na performanse u lancima opskrbe (Mikalef i sur., 2020). Ubrzani proces globalizacije i sve kompleksnije upravljanje opskrbnim lancima privuklo je pozornost znanstvenika i praktičara (Huo i sur., 2014).

U digitalnom dobu Chen i sur. (2015) na temelju istraživanja literature izjavljuju: „Upravljanje opskrbnim lancima također se može konceptualizirati kao skup digitalno omogućenih procesa između poduzeća.“ Gunasekaran i sur. (2017) izjavljuju da su istraživanja koja istražuju utjecaj velikih podataka na performanse opskrbnog lanca oskudna. Ovaj rad bavi se time kako veliki podaci mogu pomoći poduzećima da postignu konkurentnost i bolje rezultate poslovanja unutar svojeg lanca opskrbe.

Istraživanje koje je proveo Fortune na 1000 poduzeća pokazalo je da su, unatoč velikom skupljanju velikih podataka, koristi koje su poduzeća ostvarivala znatno varirala od poduzeća do poduzeća (Bean, 2017). Rezultati su pokazali da je poprilično velik jaz između poduzeća koja samo skupljaju podatke i onih koji ih analiziraju te koriste za svoju konkurentsku prednost (Jeble i sur., 2018; Mikalef i sur., 2020; Vidgen i sur., 2017). Stoga ovo istraživanje nastoji odgovoriti na pitanje kako upotreba velikih podataka poboljšava performanse lanca opskrbe.

Ovo istraživanje koristi 105 prikupljenih upitnika hrvatskih proizvodnih poduzeća s više od 20 zaposlenika za empirijsko testiranje hipoteze. Odgovarajući na postavljeno pitanje, ovo istraživanje doprinosi znanstvenoj literaturi na dva načina. Prvo, na temelju teorije dinamičkih sposobnosti poduzeća i upotrebe velikih podataka, pretpostavlja se da se tako razvija dinamička sposobnost poduzeća koja onda omogućuje oblikovanje svog lanca opskrbe za postizanje konkurentske prednosti. Drugo, ako se pretpostavi da je strategija opskrbnog lanca mehanizam koji spaja upotrebu velikih podataka i performanse opskrbnog lanca, onda treba proučiti i indirektne mehanizme koji povezuju upotrebu velikih podataka i upravljanje opskrbnim lancem (Wambai sur., 2020). Istraživanje koje pokušava odgovoriti na pitanje mogu li se veliki podaci koristiti za podršku i oblikovanje različitih opskrbnih lanaca i njihovih karakteristika svakako doprinosi literaturi iz područja upravljanja opskrbnih lanaca.

Rad je strukturiran na sljedeći način: u poglavlju 2. jest prikaz postojeće literature na temu analize velikih podataka i načina na koji je teorija dinamičkih sposobnosti povezana s velikim podacima. U poglavlju 3. objašnjene su hipoteze, dok je u poglavlju 4. opisana metodologija istraživanja. U poglavlju 5. su rezultati, a na kraju, u 6. poglavlju zaključak.

2. ANALIZA POSTOJEĆE LITERATURE I POSTAVKA HIPOTEZA

Upotreba i analiza velikih podataka proces je koji zapravo spaja resurse poduzeća s okolinom, a teorija dinamičkih sposobnosti može dobro objasniti ovaj dinamički proces (Gupta i George, 2016). Oslanjajući se na teoriju dinamičkih sposobnosti, analiza velikih podataka može se smatrati dinamičkom sposobnošću poduzeća koja može optimizirati procese lanca opskrbe i poboljšati koordinaciju lanca opskrbe (Jeble i sur., 2018; Dubey i sur., 2018). Stoga, proširujući postojeće analize i prema teoriji dinamičkih sposobnosti, u ovom bi radu upotreba velikih podataka u lancu opskrbe morala poboljšati performanse opskrbnog lanca. Xiang i sur. (2021) potvrđuju da analiza velikih podataka doprinosi upravljanju lancem opskrbe tako da je omogućeno preciznije predviđanje ponude i potražnje, povećava se efikasnost proizvodnje te se efikasnije obrađuju i isporučuju proizvodi krajnjim kupcima. Analiza velikih podataka i posljedično brže donošenje odluka u opskrbnom lancu (Lee i Mangalaraj, 2022; Tiwari i sur., 2018) poduzeću pomažu razumjeti tržišne trendove i preferencije kupaca (Janssen i sur., 2017) te smanjiti potencijalne rizike (Wang i sur., 2016).

2.1 Analiza velikih podataka

Razvoj tehnologije i interneta promijenili su način na koji poduzeća generiraju, dijele i analiziraju velike podatke (Ghasemaghahi, 2020). Analiza takvih podataka koristi poduzećima da bi donosila ispravnije odluke i stekla konkurentskih prednosti (Ghasemaghahi i sur., 2018). Chae i sur. (2014), Kalaitzi i Tsolakis (2022) i Shafiq i sur. (2020) potvrđuju da se korištenjem analize velikih podataka i njihovom primjenom u opskrbnim lancima poboljšanjem operativnih sposobnosti poduzeća može poboljšati upravljanje lancem opskrbe.

Poduzeća koja su započela digitalnu transformaciju mogu inovirati brže nego ikad prije (Tuukkanen i sur., 2022), što može poboljšati njihovu sposobnost suočavanja s poremećajima uzrokovanim izvanrednim događajima u vanjskim okruženjima. Analizom velikih podataka u realnom vremenu može se smanjiti izloženost riziku i smanjiti troškove zbog nepredviđenih događaja (Martinez-Simarro i sur., 2015). Inovacije i kontinuirano poboljšanje lanca opskrbe stvorit će dodatnu vrijednost za kupce (Ayoub i Abdallah, 2019) i dovesti do poboljšanja procesa, aktivnosti i performansi unutar lanca opskrbe (Abdallah i sur., 2021). Štoviše, inovacije u lancu opskrbe doprinose efikasnijem korištenju resursa (Seo i sur., 2014) i olakšavaju učinkovit prijenos i razmjenu informacija između svih članova lanca dobave (Abdallah i sur., 2021), što pridonosi poboljšanju učinkovitosti i performansi lanca opskrbe u cjelini.

2.2 Teorija dinamičkih sposobnosti

Postoje dva pravca izučavanja dinamičke sposobnosti poduzeća - Eisenhardt i Martin (2000) s jedne strane i Teece i sur. (1997) s druge strane. Međutim, zajedničko im je da poduzeća integriraju, grade i konfiguriraju unutarnje i vanjske sposobnosti za učinkovit odgovor na brzo promjenjivo i nepredvidivo okruženje (Chen i sur., 2015). Dinamičke sposobnosti definirane su kao procesi koji koriste resurse poduzeća, uključujući procese koordinacije s unutarnjim i vanjskim dionicima i na taj način dinamički grade svoje sposobnosti. One

omogućuju poduzećima poboljšanja u području efikasnosti proizvodnje, kvalitete, brzine i fleksibilnosti (Chen i sur., 2015), odnosno ključnim kompetencijama poduzeća. Dakle, ključne kompetencije smatraju se operativnim sposobnostima poduzeća potrebnima za svakodnevno poslovanje, na koje se nadograđuju dinamičkim putem dinamičke sposobnosti, a one trebaju dovesti do konkurentne sposobnosti poduzeća. Teorija dinamičkih sposobnosti može pomoći u objašnjenju organizacijskih procesa korištenja resursa i fokusiranja na učenje (Gupta i sur., 2019). Prema teoriji dinamičkih sposobnosti, analiza velikih podataka može se promatrati kao vrsta dinamičke sposobnosti poduzeća jer se oslanja na operativne procese koji se sastoje od izvršavanja aktivnosti uz istovremeno elektronsko bilježenje, odnosno prikupljanja velikih podataka, na kojima se vrši analiza u realnom vremenu. Konkretno, sposobnost obrade informacija i tako stvaranja znanja za daljnje učenje i prilagođavanje, osobito na vrlo dinamičnom tržištu (Chen i sur., 2015) može stvoriti konkurentsku prednost.

Dinamičke sposobnosti sastoje se od triju koraka, a to su: identifikacija (*sensing*), iskorištavanje (*seizing*) i rekonfiguracija (*reconfiguring*) (Teece, 2014). Sva tri zahtijevaju da se na pravim mjestima uzimaju podaci i onda analiziraju (velike količine podataka) u cilju uočavanja prilika i prijetnji iz okoline – identifikacija, zatim donošenje prave odluke na temelju tih analiza – iskorištavanje, te naposljetku provođenje odluke u djelo rekonfiguracijom resursa.

3. RAZVOJ HIPOTEZA

Oslanjajući se na teoriju dinamičkih sposobnosti poduzeća, koje su stvorene analizom velikih podataka, djeluju pozitivno na upravljanje opskrbnim lancem. Uz velike i raznovrsne podatke koji su analizirani u realnom vremenu, poduzeća mogu izbjeći gubitke i stvoriti konkurentsku prednost u cijelom lancu opskrbe (Srinivasan i Swink, 2017). Ova analiza može se koristiti za generiranje uvida u poslovanje prikupljanjem i analizom informacija preko primarnih aktivnosti lanca opskrbe (npr. nabava, proizvodnja, distribucija), čime se u konačnici utječu na uspješnost opskrbnog lanca (Chen i sur., 2015).

Integracija i interpretacija informacija rezultata analize velikih podataka poduzećima može omogućiti točnije odluke u koordinaciji s partnerima u lancu opskrbe umjesto da se oslanjaju na prošlo iskustvo i intuiciju menadžera. Neizvjesnosti (npr. dostupnost opskrbe, zahtjevi kupaca i kapaciteti) mogu se smanjiti. Na primjer, može pomoći poduzeću da točnije predviđa potražnju kako bi menadžerima omogućilo donošenje optimiziranih odluka u vezi s raspodjelom resursa i pozicioniranjem proizvoda. Ovo učinkovito smanjenje neizvjesnosti potražnje može smanjiti troškove isporuke proizvoda/usluga, čime se poboljšava učinkovitost i produktivnost cijelog lanca opskrbe (Chen i sur., 2015; Srinivasan i Swink, 2017). Analiza velikih podataka može pomoći poduzećima da poboljšaju brzinu tržišnog odgovora i ubrzaju proces razvoja novog proizvoda/usluge (Grover i sur., 2018; Jeble i sur., 2018). Na primjer, pomoću njih poduzeća mogu prikupljati komentare kupaca na internetu, razumjeti njihove potrebe i pružiti pravovremenu povratnu informaciju. Mogu provoditi ciljani marketing i mogu dobiti ideje za nove proizvode te povećati lojalnost kupaca. Sukladno tome, predlaže se sljedeća hipoteza:

H1. Analiza velikih podataka ima pozitivan izravan učinak na performanse lanca opskrbe.

4. METODOLOGIJA

4.1 Prikupljanje podataka

Kako bi se empirijski testirala hipoteza, provedena je anketa za prikupljanje podataka. Uglavnom su odgovarali zaposlenici iz opskrbe, prodaje, IT i operativni menadžeri. Empirijsko istraživanje temeljeno na upitniku dobro je dokumentirana metoda za prikupljanje smjera i identificiranje odnosa među varijablama u uzorku. Prethodna istraživanja potvrdila su da se generalizirani rezultati mogu dobiti putem metoda upitnika, a mogu se i ponoviti (Mikalef i sur., 2020). Kako bi se osigurala valjanost podataka iz upitnika, usvojene su varijable na temelju istraživanja literature sa sličnom temom. Kontaktirali su se direktori poduzeća, koji su upitnik prosljedili rukovoditeljima jer bi oni mogli najbolje na njega odgovoriti. Na prvoj stranici upitnika istaknuta je akademska svrha ankete i zajamčena anonimnost i povjerljivost podataka. E-mail adrese i imena generalnih direktora i predsjednika uprave dobivena su iz baze subjekata Hrvatske gospodarske komore. Anketni upitnik po potrebi se provodio i telefonskim intervjuom. Nakon mjesec dana (svibanj 2020. godine) dobiveno je 105 popunjenih upitnika. Stopa odgovora bila je 7 %. Uzorak je varirao u različitim industrijama, a njegove specifične demografske karakteristike prikazane su u Tablici 1.

Kako bi se testirala potencijalna pristranost neodgovora, proveden je hi-kvadrat test između prvih i posljednjih 25 % ispitanika. Promatrano u smislu kontrolnih varijabli, nije bilo statistički značajnih razlika između dviju skupina (Armstrong i Overton, 1977). Ovaj rezultat pokazao je da u ovome istraživanju ne postoji pristranosti neodgovora. Za provjeru *Common method bias* (CMB) korištena je statistička metoda za ispitivanje CMB-a, odnosno Harmanov jednofaktorski test. Rezultati su pokazali da prvi faktor objašnjava 19,23 % varijance, što je manje od 30 %, što dokazuje da CMB nije problem u ovom istraživanju (Podsakoff i sur., 2003).

Varijable za analizu velikih podataka preuzete su iz Chen i sur. (2015). Ova varijabla uključuje pitanja skuplja li poduzeće podatke, analizira li ih te intenzitet korištenja na ljestvici od nisko -1 do 3 – visoko. Ova varijabla kreirana je u AMOSU ver. 29 i nakon potvrđujuće faktorske analize vraćena u datoteku SPSS za provedbu hijerarhijske regresije.

Učinkovitost lanca opskrbe mjerena je varijablama preuzetim iz Huo i sur. (2014). Varijable su: vrijeme razvoja novog proizvoda, sposobnost isporuke na vrijeme mjereno postotkom isporuka na vrijeme, postojanje direktne elektronske komunikacije s dobavljačima (kao npr. EDI – *electronic data interchange*). Ova varijabla također je kreirana u AMOSU ver. 29 i nakon potvrđujuće faktorske analize vraćena u datoteku SPSS za provedbu hijerarhijske regresije.

Kontrolne su varijable standardne i uzete s malom modifikacijom iz Lee i Tang (2018). Razmatrana je veličina poduzeća u tri kategorije (mala, srednja i velika poduzeća). Kompleksnost proizvoda u tri kategorije od jednostavnog do vrlo kompleksnog, te intenzitet industrije u četiri kategorije, kako je prikazano u Tablici 1.

5. ANALIZA PODATAKA I REZULTATI

5.1 Rezultati istraživanja

Struktura uzorka dana je u Tablici 1.

Tablica 1. Demografske karakteristike uzorka

Broj zaposlenika u tri skupine	Frekvencija	Postotak
Malo <50 zaposlenih	39	37.1
Srednje 50 – 249 zaposlenih	46	43.8
Veliko > 250 zaposlenih	20	19
Ukupno	105	100
Kompleksnost proizvoda		
Jednostavni proizvodi	23	21.9
Srednja kompleksnost	42	40
Kompleksni proizvodi	37	35.2
Nema podataka	3	2.9
Ukupno	105	100
Intenzitet industrije		
Niska razina tehnologije	39	37.1
Srednja – niska razina tehnologije	34	32.4
Srednja – visoka razina tehnologije	28	26.7
Visoka razina tehnologije	4	3.8
Ukupno	105	100

Izvor: vlastito istraživanje

Tablica 1. prikazuje demografske karakteristike promatranih poduzeća u uzorku. Nešto je više malih (37 %) i srednjih poduzeća (44 %) u odnosu na velika, kojih je samo (19 %). Dominiraju proizvodi srednje (40 %) do visoko kompleksnih (35 %). U uzorku je ipak najviše poduzeća koja spadaju u niski intenzitet industrije (37 %), u što spadaju NKD klasifikacije 10 -18 i 31 i 32.

Tablica 2. Korelacije među varijablama

	Učinkovitost lanca opskrbe	Tehnološka intenzivnost	Broj zaposlenih	Kompleksnost proizvoda	Analiza velikih podataka
Učinkovitost lanca opskrbe	1				
Tehnološka intenzivnost	-0,013	1			
Broj zaposlenih	0,393***	-0,024	1		
Kompleksnost proizvoda	0,151	0,078	0,093	1	
Analiza velikih podataka	0,221**	0,115	0,387***	0,074	1

Izvor: vlastito istraživanje

Iako će se provesti hijerarhijska regresija, korisne spoznaje mogu se dobiti i već iz korelacijske tablice – Tablice 2. Na primjer, što je veće poduzeće, učinkovitost je lanca opskrbe bolja (2. stupac 3. redak). To se možda može objasniti time da veća poduzeća imaju više ljudskih i financijskih resursa. Isto tako, postoji i jaka i signifikantna veza između analize velikih podataka i učinkovitosti lanca opskrbe (2. stupac 5. redak). Također se vidi jaka i signifikantna veza između veličine poduzeća i analize velikih podataka (4. stupac, 5. redak), vjerojatno zbog toga što veća poduzeća imaju više ljudskih i financijskih resursa od malih i srednjih poduzeća. Kompleksnost proizvoda djeluje pozitivno, ali ne i signifikantno na učinkovitost lanca opskrbe. Tehnološka intenzivnost nije signifikantna pa se može zaključiti da ne djeluje na uspješnost lanca opskrbe.

Tablica 3. Rezultat hijerarhijske regresije

Model	Zavisna varijabla: Učinkovitost lanca opskrbe	Standardizirana	Sig.	Kolinearnost	
				Tolerancija	VIF
		Beta			
1	(Constant)		0,047		
	Tehnološka intenzivnost	-0,013	0,913	0,993	1,007
	Broj zaposlenih	0,382	0,002	0,99	1,01
	Kompleksnost proizvoda	0,117	0,337	0,985	1,015
2	(Constant)		0,047		
	Tehnološka intenzivnost	-0,023	0,852	0,976	1,025
	Broj zaposlenih	0,351	0,01	0,84	1,19
	Kompleksnost proizvoda	0,115	0,349	0,984	1,016
	Analiza velikih podataka	0,279	0,042	0,834	1,199
	R	0,416			
	R ²	0,173	0,023		

Izvor: vlastito istraživanje

Kako bi se testirala hipoteza provedena je hijerarhijska regresija uz korištenje SPSS 29, koja je prikazana u Tablici 3. H1 pretpostavlja da analiza velikih podataka ima direktan učinak na učinkovitost lanca opskrbe. Rezultati su prikazani u Tablici 3. i pokazuju da je učinak analize velikih podataka na učinkovitost lanca opskrba pozitivan i značajan ($\beta = 0,279$, $p < 0,042$), čime se H1 potvrđuje. Također se vidi da je značajna kontrolna varijabla veličine poduzeća. Cijeli model ima signifikantan regresijski koeficijent $R = 0,416$, Sig. $0,023$, a $R^2 = 17,3\%$. Ovaj koeficijent determinacije pokazuje da nezavisna varijabla *analiza velikih podataka* doprinosi $17,3\%$ u povećanju zavisne varijable, odnosno učinkovitosti lanca opskrbe.

Dakle, hipoteza je potvrđena, tj. analiza velikih podataka zaista direktno djeluje na učinkovitost lanca opskrbe. Međutim, vidljivo je i da je veličina poduzeća značajna, tj. što je poduzeće veće, veća je vjerojatnost da će koristiti i analizirati velike podatke te djelovati na učinkovitost lanca opskrbe.

5.2 Rasprava

Glavni je cilj ovoga istraživanja istražiti kako analiza velikih podataka djeluje na uspješnost lanca opskrbe. Na temelju teorije dinamičkih sposobnosti, može se zaključiti da analiza velikih podataka može poboljšati uspješnost lanca opskrbe putem dinamičke obrade informacija i time stvoriti konkurentsku prednost ne samo svoga poduzeća nego i lanca opskrbe u cjelini. Empirijski rezultati pokazuju da analiza velikih podataka ima pozitivan, izravan učinak na uspješnost lanca opskrbe, što je u skladu s rezultatima prethodnih istraživanja (Akter i sur., 2016; Ghasemaghaei i sur., 2018).

Ovaj rad daje dva velika teorijska doprinosa postojećoj literaturi. Prvo, iako su istraživanja u obliku studija slučajeva pokazala da analiza velikih podataka ima pozitivan, izravan učinak na poslovanje poduzeća, nedostaju empirijska istraživanja na ovu temu (Mikalef i sur., 2020). Na primjer, Jeble i sur. (2018) tvrde da stvaranje konkurentске prednosti na temelju analize velikih podataka zahtijeva različite vrste organizacijskih resursa i pokazuje pozitivan učinak na ekološki, društveni i ekonomski učinak. Gupta i sur. (2020) otkrili su da analiza velikih podataka, koja se može smatrati dinamičkom sposobnošću, poduzećima pomaže u postizanju boljih proizvodnih performansi. Teorijskim dijelom ovoga rada otkriveno je da većina prethodnih empirijskih istraživanja pokazuje izravan odnos analize velikih podataka i pozitivnog poslovanja poduzeća. Međutim, u potpunosti je zanemaren odnos s performansama lanca opskrbe (Gupta i sur., 2020; Jeble i sur., 2018; Mikalef i sur., 2020). Ovaj rad doprinosi smanjenju jaza u literaturi koja analizira upotrebu velikih podataka i performansi lanca opskrbe, a na temelju teorije dinamičkih sposobnosti. Konkretno, sposobnost analize velikih podataka može se promatrati kao alat pomoću kojega se djeluje na operativne sposobnosti poduzeća. One tako postaju dinamičke sposobnosti i kao takve mogu pomoći u oblikovanju i olakšavanju rada opskrbnog lanca (Mikalef i sur., 2020; Abbasi i sur., 2016). Drugim riječima, informacije generirane analizom velikih podataka ne samo da mogu pomoći u identifikaciji mogućnosti i prijetnji nego i biti pomoć menadžerima kod odabira odgovarajuće strategije za poboljšanje performansi opskrbnog lanca, a na temelju tržišnih promjena u realnom vremenu. Empirijski rezultati naglašavaju argumente Janssena i sur. (2017), koji su istaknuli da kvaliteta odluke vrhovnog menadžmenta uvelike ovisi o rezultatima generiranima analizom velikih podataka.

5.3 Praktične implikacije

Rezultati ovog rada imaju nekoliko menadžerskih implikacija vezanih za analizu velikih podataka radi poboljšanja performansi lanca opskrbe. Prvo, u sadašnjoj, digitalnoj eri menadžeri poduzeća trebali bi shvatiti važnost korištenja analize velikih podataka kao mogućnosti dinamičke obrade informacija u opskrbnom lancu. Poduzeća ih mogu koristiti za prikupljanje informacija i analizu kako bi poboljšale performanse lanca opskrbe. Na primjer, Southwest Airlines razvio je metodu govorne analitike, specifične primjene obrade velikih podataka, za razgovore s klijentima, ponude personalizirane usluge i dr. Saznanja generirana iz različitih vrsta podataka mogu poboljšati postojeće operativno djelovanje i zadovoljstvo kupaca (Erevelles i sur., 2016). Stoga bi menadžeri trebali pridavati važnost analizi velikih podataka radi poboljšanja performansi lanca opskrbe.

Drugo, menadžeri bi trebali biti svjesni vrijednosti analize velikih podataka u strateškim odlukama vezanima za opskrbeni lanac. Ona, od internih funkcija do vanjskih partnera, može pomoći poduzećima u prepoznavanju prilika i prijetnji kako bi poboljšali performanse lanca opskrbe i agilnost. Uz pomoć analize velikih podataka, menadžeri mogu donositi odluke o odgovarajućoj strategiji lanca opskrbe. Na primjer, Procter and Gamble iskoristio je analizu velikih podataka, što je omogućilo brzu proizvodnju traženih proizvoda te usavršavanje logističkih procesa, kako bi se narudžbe kupaca isporučivale na vrijeme (Srinivasan i Swink, 2017). Također, Walmart koristi analizu velikih podataka za odjel podrške kupcima. Walmart je koristi i u kontinuiranoj analizi ponašanja kupaca te u skladu s time odabire preciznu marketinšku strategiju (Wamba i sur., 2020).

Dinamičke sposobnosti sastoje se od triju koraka: identifikacija, iskorištavanje i rekonfiguracija (Teece, 2014). Sva tri zahtijevaju da se na pravim mjestima uzimaju podaci i onda analiziraju (velike količine podataka) u cilju uočavanja prilika i prijetnji iz okoline – identifikacija, zatim donošenje prave odluke na temelju tih analiza – iskorištavanje, te naposljetku provođenje odluke u djelo rekonfiguracijom resursa.

5.4 Ograničenja istraživanja

Uz ovo istraživanje treba spomenuti nekoliko ograničenja. Prvo, u smislu uzoraka, upitnik je distribuiran cijelom proizvodnom sektoru Hrvatske, ali svejedno je odziv mali, svega 7 %. Drugo, uslužni sektor nije ni dotaknut pa nije moguće generalizirati rezultate, a npr. trgovine su vodeće po skupljanju i obradi velikih podataka. Treće je nedostatak svih upitnika, a to je da su istraživanja provedena u određenom trenutku i ne mogu pratiti razvoj ili odgovore na izazove iz okoline. U tu bi svrhu još trebalo napraviti i dubinske intervjue s poduzećima da se vidi kako su uveli i s kojim su se izazovima susreli pri uvođenju analize velikih podataka, te kako je to djelovalo na njihove partnere nizvodno u lancu opskrbe.

6. ZAKLJUČAK

Zbog nedostatka istraživanja o upotrebi i analizi velikih podataka i njihovoj mogućnosti da poboljšaju operativno poslovanje lanca opskrbe, te oslanjanjem na teoriju dinamičkih sposobnosti, dokazano je da ona zaista poboljšava performanse opskrbnog lanca.

Trenutačno je to privilegija samo većih poduzeća (po broju zaposlenih) jer u alate za analizu velikih podataka treba uložiti znatna sredstva.

Također treba naglasiti i da se podaci moraju skupljati u poduzeću i od ostalih partnera u lancu opskrbe da bi analiza imala smisla, a to onda zahtijeva partnerski odnos s članovima lanca opskrbe, što nije uvijek lako postići.

Dokazano je kako poduzeća mogu iskoristiti analizu velikih podataka u opskrbnom lancu, povećati efikasnost i smanjiti potencijalne rizike (Seyedan i Mafakheri, 2020; Xiang i sur., 2021), te povećati zadovoljstvo kupaca (Kalaitzi i Tsolakis, 2022), a time stvoriti konkurentsku prednost ne samo za poduzeće nego i na razini lanca opskrbe.

LITERATURA

- Abdallah, A. B., Alfar, N.A. i Alhyari, S. (2021). The effect of supply chain quality management on supply chain performance: the indirect roles of supply chain agility and innovation. *International Journal of Physical Distribution and Logistics Management*, 51(7), str. 785-812.
- Agarwal, R. i Dhar, V. (2014). Big data, data science, and analytics: the opportunity and challenge for IS research. *Information System Research*, 25, str. 443-448.
- Akter, S., Wamba, S. F., Gunasekaran, A., Dubey, R. i Childe, S. J. (2016). How to improve firm performance using big data analytics capability? *International Journal of Production Economics*, 182, str. 113-131.
- Armstrong, J. S. i Overton, T. S. (1977). Estimating nonresponse bias in mail surveys. *Journal of Marketing Research*, 14(3), str. 396-402.
- Ayoub, H. F. i Abdallah, A. B. (2019). The effect of supply chain agility on export performance: the mediating roles of supply chain responsiveness and innovativeness. *Journal of Manufacturing Technology Management*, 30(5), str. 821-839.
- Chae, B., Olson, D. i Sheu, C. (2014). The impact of supply chain analytics on operational performance: a resource-based view *International Journal of Production Research*, 52(16), str. 4695-4710.
- Chen, D. Q., Preston, D. S. i 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.
- Dubey, R., Luo, Z., Gunasekaran, A., Akter, S., Hazen, B. T. i Douglas, M. A. (2018). Big data i predictive analytics in humanitarian supply chains. *The International Journal of Logistics Management*, 29(2), str. 485-512.
- Eisenhardt, K.M. i Martin, J.A. (2000). Dynamic capabilities: what are they? *Strategic Management Journal*, 21(10-11), str. 1105-1121.
- Erevelles, S., Fukawa, N. i Swayne, L. (2016). Big data consumer analytics i the transformation of marketing. *Journal of Business Research*, 69(2), str. 897-904.
- Ghasemaghaei, M. (2020). Improving organizational performance through the use of big data. *The Journal of Computer Information Systems*, 60(5), str. 395-408.

- Ghasemaghaei, M., Ebrahimi, S. i Hassanein, K. (2018). Data analytics competency for improving firm decision making performance. *The Journal of Strategic Information Systems*, 27(1), str. 101-113.
- Gupta, M. i George, J. F. (2016). Toward the development of a big data analytics capability. *Information and Management*, 53(8), str. 1049-1064.
- Gupta, S., Qian, X., Bhushan, B. i Luo, Z. (2019). Role of cloud ERP and big data on firm performance: a dynamic capability view theory perspective. *Management Decision*, 57(8), str. 1857-1882.
- Huo, B., Zhao, X. i Zhou, H. (2014). The effects of competitive environment on supply chain information sharing i performance: an empirical study in China. *Production and Operations Management*, 23(4), str. 552-569.
- Janssen, M., van der Voort, H. i Wahyudi, A. (2017). Factors influencing big data decision-making quality. *Journal of Business Research*, 70, str. 338-345.
- Jeble, S., Dubey, R., Childe, S.J., Papadopoulos, T., Roubaud, D. i Prakash, A. (2018). Impact of big data and predictive analytics capability on supply chain sustainability. *The International Journal of Logistics Management*, 29(2), str. 513-538.
- Kalaitzi, D. i Tsolakis, N. (2022). Supply chain analytics adoption: determinants and impacts on organisational performance and competitive advantage. *International Journal of Production Economics*, str. 108466.
- Lee, I. i Mangalaraj, G. (2022). Big data analytics in supply chain management: a systematic literature review and research directions, *Big Data and Cognitive Computing*, 6(1), str. 1-17.
- Lee, R.P. i Tang, X. (2018). Does it pay to be innovation i imitation oriented? An examination of the antecedents and consequences of innovation and imitation orientations. *Journal of Product Innovation Management*, 35(1), str. 11-26.
- Mikalef, P., Krogstie, J., Pappas, I.O. i Pavlou, P. (2020). Exploring the relationship between big data analytics capability and competitive performance: the mediating roles of dynamic and operational capabilities. *Information and Management*, 57(2), str. 103-169.
- Muller, O., Fay, M. i vom Brocke, J. (2018). The effect of big data and analytics on firm performance: an econometric analysis considering industry characteristics. *Journal of Management Information Systems*, 35(2), str. 488-509.
- Seo, Y.J., Dinwoodie, J. i Kwak, D. W. (2014). The impact of innovativeness on supply chain performance: is supply chain integration a missing link? *Supply Chain Management: An International Journal*, 19(5/6), str. 733-746.
- Seyedan, M. i Mafakheri, F. (2020). Predictive big data analytics for supply chain demand forecasting: methods, applications, and research opportunities. *Journal of Big Data*, 7(1), str. 1-22.
- Shafiq, A., Ahmed, M. U. i Mahmoodi, F. (2020). Impact of supply chain analytics and customer pressure for ethical conduct on socially responsible practices and performance: an exploratory study. *International Journal of Production Economics*, 225, str. 107571.

- Srinivasan, R. i Swink, M. (2017). An investigation of visibility and flexibility as complements to supply chain analytics: an organizational information processing theory perspective. *Production and Operations Management*, 27(10), str. 1849-1867.
- Teece, D. J., Pisano, G. i Shuen, A. (1997). Dynamic capabilities and strategic management. *Strategic Management Journal*, 18(7), str. 509-533.
- Tiwari, S., Wee, H.M. i Daryanto, Y. (2018). Big data analytics in supply chain management between 2010 i 2016: insights to industries. *Computers i Industrial Engineering*, 115, str. 319-330.
- Tuukkanen, V., Wolgsjo, E. i Rusu, L. (2022). Cultural values in digital transformation in a small company. *Procedia Computer Science*, 196, str. 3-12.
- Vidgen, R., Shaw, S. i Grant, D. B. (2017). Management challenges in creating value from business analytics. *European Journal of Operational Research*, 261(2), str. 626-639.
- Wamba, S. F., Gunasekaran, A., Akter, S. i Dubey, R. (2020). The performance effects of big data analytics and supply chain ambidexterity: the moderating effect of environmental dynamism. *International Journal of Production Economics*, 222, str. 107-498.
- Wang, G., Gunasekaran, A., Ngai, E. W. i Papadopoulos, T. (2016). Big data analytics in logistics and supply chain management: certain investigations for research and applications. *International Journal of Production Economics*, 176, str. 98-110.
- Xiang, L. Y., Hwang, H. J., Kim, H.K., Mahmood, M., Dawi, N. M. (2021). *The Use of Big Data Analytics to Improve the Supply Chain Performance in Logistics Industry*. In: Kim, H., Lee, R. (eds) *Software Engineering in IoT, Big Data, Cloud and Mobile Computing*. Studies in Computational Intelligence, vol 930. Springer, Cham.