

DEJAVNIKI PODATKOVNE ZRELOSTI IN PODATKOVNO- VODENA ORGANIZACIJA

MIRJANA KLJAJIĆ BORŠTNAR, BLAŽ GAŠPERLIN,
ANDREJA PUCIHAR

Univerza v Mariboru, Fakulteta za organizacijske vede, Kranj, Slovenija
mirjana.klajic@um.si, blaz.gasperlin1@um.si, andreja.pucihar@um.si

Sinopsis V zadnjih letih so digitalne tehnologije povzročile spremembe v načinu poslovanja organizacij, omogočile razvoj digitalnih izdelkov in storitev, nove načine komuniciranja, sodelovanja in večjo povezljivost. Del teh sprememb so tudi podatki, ki so vedno bolj pomembni za učinkovito upravljanje znanja ter sprejemanje pravočasnih in podatkovno podprtih odločitev. Sodobna organizacija mora poleg digitalnih tehnologij obvladovati tudi podatke, znati z njimi učinkovito upravljati, imeti znanja in razvite sposobnosti podatkovne analize in jasno razumeti vrednost pridobljenih podatkov, kar predstavlja osnovo podatkovno zrele organizacije. Podatkovna zrelost se nanaša na različne vidike (kakovost podatkov, varnost podatkov, upravljanje podatkov, življenjski cikel podatkov idr.), zato moramo upoštevati različne dejavnike, s katerimi lahko celovito ocenimo podatkovno zrelost organizacije. V prispevku na podlagi pregleda literature identificiramo dejavnike, na podlagi katerih lahko ocenimo podatkovno zrelost malih in srednje velikih podjetij.

Ključne besede:
digitalna
preobrazba,
podatki,
podatkovna
zrelost,
modeli podatkovne
zrelosti,
dejavniki
podatkovne
zrelosti

DATA MATURITY FACTORS AND DATA-DRIVEN ORGANIZATION

MIRJANA KLJAJIĆ BORŠTNAR, BLAŽ GAŠPERLIN,

ANDREJA PUCIHAR

University of Maribor, Faculty of Organizational Sciences, Kranj, Slovenia
mirjana.kljaic@um.si, blaz.gasperlin1@um.si, andreja.pucihar@um.si

Abstract In recent years, digital technologies have led to changes in the way organizations operate, enabling the development of digital products and services, new ways of communicating, collaborating and increasing connectivity. Part of these changes is also data, which is increasingly important for effective knowledge management and timely and data-supported decision-making. In addition to digital technologies, a modern organization must also manage data, know how to manage it effectively, have knowledge and developed skills of good data analysis and clearly understand the value of acquired data, which is the basis of a data-mature organization. Data maturity refers to various aspects (data quality, data security, data management, data life cycle, etc.), so we need to consider various factors that can comprehensively assess the data maturity of the organization. Based on the literature review, we identify data maturity models and their factors through which we can assess the data maturity of small and medium-sized enterprises.

Keywords:
digital transformation,
data, data maturity,
data maturity
models,
data maturity
factors

1 **Uvod**

Razvoj in napredek digitalnih tehnologij sta v zadnjih letih povzročila odmak od tradicionalnega načina poslovanja in premik k sodobnejši digitalno naravnani organizaciji. V ospredju je uporaba digitalnih rešitev, ki organizacijam olajšajo vsakodnevno poslovanje, jim pomagajo pri razvoju novih izdelkov in storitev in novih poslovnih modelov. Z uporabo digitalnih tehnologij lahko organizacije bolje naslavljajo potrebe sodobne digitalne družbe in zagotavljajo konkurenčnost (Verhoef et al., 2019). Digitalne tehnologije so dodobra spremenile gospodarstvo in družbo, vzpodbudile razvoj organizacij v smeri večje digitalne zrelosti in s tem k digitalni preobrazbi (European Commission, 2020c; OECD, 2019). Pomemben del digitalne preobrazbe predstavlja podatki. Digitalne tehnologije (npr. internet stvari, računalništvo v oblaku, digitalni dvojniki) prispevajo k eksponentnemu naraščanju količine podatkov. Podatki predstavljajo priložnost za optimizacijo procesov, boljše razumevanje potreb kupcev, boljše odločanje, ustvarjanje dodane vrednosti in inoviranje. Vendar pa prave vrednosti iz podatkov ni mogoče pridobiti brez celovitega obvladovanja in upravljanja podatkov, kar pa ni zgolj tehnološki, pač pa tudi organizacijski izzik. Vse večji pomen podatkov zaznamo tudi v znanstveni literaturi (Anderson, 2015; Carillo, 2017; Ciuriak, 2018; Gandhi et al., 2018) in publikacijah svetovalnih podjetij (Accenture, 2018; Baltassis et al., 2019; Deloitte, 2018; IBM, 2007). Velik poudarek pri ozaveščanju pomembnosti podatkov in njihovem upravljanju pa se odraža tudi na nivoju Evropske unije. Na omenjenem področju so bile oblikovane različne strategije, akti in iniciative (European Commission, 2020b, 2020a, 2020c; GAIA-X, 2021).

Podatki organizacijam med drugim pomagajo pri odkrivanju novih spoznanj (Erevelles et al., 2016; Jukić & Sharma, 2015), spremeljanju trendov na trgih (Hossain idr., 2020), sprejemanju bolj informiranih odločitev (Ciampi et al., 2021; Kljajić Borštnar & Pucihar, 2021), oblikovanju bolj prilagojene ponudbe za stranke (Anshari et al., 2019) in razvijanju novih izdelkov ter storitev, ki so dodatno obogateni tudi s podatki (Faroukhi et al., 2020; Hanafizadeh & Harati Nik, 2020). Sodobna organizacija mora poleg obvladovanja digitalnih tehnologij torej obvladovati tudi podatke, ki jih tekom poslovanja ustvarja ali pa se generirajo preko zunanjih virov (družbena omrežja, odprti podatki). Količina podatkov se zaradi tehnoloških sprememb in stalne potrebe po razvoju digitalno bolj zrele organizacije povečuje, s tem pa raste tudi potreba po učinkovitem obvladovanju in upravljanju podatkov,

razvoju sposobnosti dobre analize podatkov in jasnem razumevanju vrednosti, ki jo podatki lahko nosijo. Uspešno obvladovanje podatkov je predpogoj za preobrazbo v digitalno zrelo organizacijo (Weritz et al., 2020). Pomembno je, da podjetja znajo povezati poslovno strategijo s strategijo digitalizacije in podatkovno strategijo (Correani t ale., 2020), kar se na koncu lahko kaže v učinkovitosti in uspešnosti poslovanja organizacije (Mahdi Nasrollahi et al., 2021).

Da imajo podatki veliko finančno vrednost ocenjuje tudi Evropska komisija (European Comission, 2021), ki je leta 2019 ocenila vrednost podatkovne ekonomije EU na 325 milijard evrov, kar je predstavljalo 2,6 % bruto družbenega proizvoda (BDP) (Cattaneo et al., 2020), do leta 2025 pa ocenjuje porast vrednosti na 550 milijard evrov in 4-% BDP. Kljub navedenim dejstvom, ki pričajo o vse večjem pomenu podatkov, pa je uporaba podatkovne analitike v podjetjih še vedno šibka. Po podatkih (SURS, 2020) svoje podatke analizira le 27,5 % velikih podjetij. Pri malih in srednje velikih podjetjih (MSP) pa je stanje še bolj zaskrbljujoče, saj podatke analizira le 3,5 % malih podjetij in 9,4 % srednje velikih podjetij (SURS, 2020).

Nezmožnost sledenja hitremu razvoju okolja in prilagajanja trgu lahko vodi podjetja v propad, kar se je izkazalo tudi ob trenutni Covid-19 pandemiji (Gourinchas et al., 2020). Ker pa MSP v Evropi predstavljajo 99 % vseh podjetij in tako imenovano hrbtenico gospodarstva (European Investment Bank, 2018), je pomembno, da znamo podjetjem, predvsem MSP, pomagati na poti digitalne preobrazbe tudi na področju upravljanja podatkov (OECD, 2021). Ocena podatkovne zrelosti MSP predstavlja temelj za vzpostavitev načrta aktivnosti, ki bodo podjetja privedle do želenega cilja. V ta namen obstaja vrsta podpornih aktivnosti, kot so na primer vavčerji za digitalizacijo, ki MSP pomagajo pri preobrazbi v digitalno zrela in konkurenčna podjetja (<https://dihslovenia.si/>). Da bi imele podporne aktivnosti prave učinke, je potrebno najprej poznati trenutno stanje in potrebe podjetja.

Pri tem si lahko pomagamo z modeli za ocenjevanje zrelosti podjetij na različnih področjih. Skladno z razvojem področij so se v zadnjih letih razvili tudi modeli za ocenjevanje digitalne zrelosti in podatkovne zrelosti. Tovrstni modeli nam torej pomagajo prepozнатi potrebe, ciljno dodeliti pomoči in po določenem času oceniti učinke pomoči, kar smo že pokazali na primeru ocene potenciala uporabe storitev superračunalnika v oblaku (Kljajić Borštnar et al., 2015) in ocene digitalne zrelosti MSP (Kljajić Borštnar & Pucihar, 2021). Ob pregledu obstoječih modelov za

ocenjevanje podatkovne zrelosti smo ugotovili, da so ti večinoma namenjeni za ocenjevanje podatkovne zrelosti v večjih podjetjih. Nekateri modeli se usmerjajo na bolj tehnološke vidike ocenjevanja zrelosti ali pa celo na ocenjevanje pripravljenosti podjetij za upravljanje masovnih podatkov (Farzaneh et al., 2019; Nasrollahi & Ramezani, 2020; Olszak & Mach-Król, 2018). Modela, ki bi bil namenjen ocenjevanju podatkovne zrelosti MSP, v literaturi nismo zasledili.

Namen prispevka je iz obstoječih teorij in prakse identificirati dejavnike podatkovne zrelosti, ki so relevantni za MSP. Za ta namen smo pripravili celovit pregled obstoječih modelov za ocenjevanje podatkovne zrelosti in opredelili relevantne dejavnike za merjenje podatkovne zrelosti v MSP. S tem smo odgovorili na naslednje raziskovalno vprašanje: »Kateri dejavniki so relevantni za ocenjevanje podatkovne zrelosti v MSP?«

2 Teoretične osnove

Podatkovna zrelost organizacije se nanaša na sposobnost zbiranja, shranjevanja in preoblikovanja podatkov ter poročanja, hkrati pa tudi na izgradnjo procesov, ki zahtevajo odločanje na podlagi podatkov (Rogers, 2020). Nekateri avtorji (Marchildon et al., 2018) razumejo podatkovno zrelost kot lastnost podatkovnega upravljanja in obseg, v katerem je organizacija razvila in uporabila procese, politike, prakse in strukture, ki so potrebne za optimizacijo zbiranja, shranjevanja, uporabe in razširjanja svojih podatkov kot organizacijskega vira. Peña idr. (2018) podatkovno zrelost opredeljujejo kot sposobnost upravljanja procesov (velikih) podatkov. Podatkovno zrelost razumemo kot zmožnost podjetja učinkovito obvladovati podatke, na podlagi podatkov izvajati dnevne aktivnosti in sprejemati odločitve, uporabljati podatke za ustvarjanje dodane vrednosti in konkurenčne prednosti. Izhajajoč iz definicij, podatkovno zrelost obravnavamo z različnih vidikov (kakovost podatkov, varnost podatkov, življenjski cikel podatkov idr.), ki se med seboj tudi prepletajo, zato je oblikovanje celovitega modela, s katerim bo mogoče oceniti podatkovno zrelost malih in srednje velikih podjetij, zahtevna naloga.

Za zagotovitev celovite ocene podatkovne zrelosti organizacije moramo podatkovno zrelost obravnavati z vidika več dejavnikov oziroma kriterijev, kot so na primer kakovost podatkov (Günther et al., 2019; Loshin, 2011; Ryu et al., 2006), varnost podatkov (Spruit & Pietzka, 2015a), zasebnost podatkov (Guangming idr.,

2017; Marchildon et al., 2018), podatkovna kultura (Kiron et al., 2013; Sternkopf & Mueller, 2018), uporaba digitalnih tehnologij, s katerimi organizacija zajema in analizira svoje podatke (Parra et al., 2019; Peña et al., 2018), upoštevanje razvitiosti podatkovne arhitekture (Guangming et al., 2017; Ulrich, 2010) in druge. Podatkovne zrelosti tako ne moremo oceniti le z upoštevanjem enega kriterija ali dejavnika, ampak skozi prizmo več posameznih, zato jo moramo obravnavati kot večkriterijski problem. Zelo pomemben je življenjski cikel upravljanja podatkov (Badia, 2020; Shah et al., 2021), ki predstavlja osnovo podatkovne zrelosti in vključuje zajem podatkov, njihovo hrambo, analizo, uporabo, deljenje, arhiviranje in uničenje.

Za lažji vpogled in oceno stanja uporabe podatkov, njihovega izkoriščanja in upravljanja so se poleg modelov za oceno digitalne zrelosti (Chalias & Hess, 2016; Igartua et al., 2018; Schumacher et al., 2016; Valdez de Leon, 2016) pričeli razvijati tudi modeli za oceno podatkovne zrelosti (Heredia-Vizcaíno & Nieto, 2019; Parra et al., 2019; Ryu et al., 2006; Sternkopf & Mueller, 2018), s pomočjo katerih lahko identificiramo posamezne dejavnike podatkovne zrelosti. Kljub stalnemu razvoju modelov podatkovne zrelosti je med pregledom literature še vedno zaznati pomanjkanje modelov, ki bi bili usmerjeni v mala in srednje velika podjetja, kot ugotavljata (Begg & Caira, 2012). To na primer nakazujejo tudi modeli avtorjev (Marchildon et al., 2018; Saputra et al., 2018; Sen et al., 2012), ki pri oceni podatkovne zrelosti med dejavnike pristevarajo vključenost podatkovnih skrbnikov in odbora za upravljanje podatkov, opredelitev podatkovnega slovarja ter razvitost podatkovnega skladišča, česar pa mala in srednje velika podjetja običajno zaradi omejenih virov nimajo. Mala in srednje velika podjetja zaostajajo predvsem zaradi finančnih in kadrovskih virov, ki so pomembni za uresničevanje in napredek podatkovne zrelosti (Bookelmann & Sneep, b. d.; Zimmermann, 2016). V primeru malih in srednje velikih podjetij je zato potrebna prilagoditev nabora dejavnikov, s katerimi lahko podatkovno zrelost ocenimo. V tej smeri je nastala potreba po razvoju novega modela za oceno podatkovne zrelosti, ki bo malim in srednje velikim podjetjem bolj prilagojen.

3 Metodologija

Pri pregledu dejavnikov za oceno podatkovne zrelosti malih in srednje velikih podjetij smo kot raziskovalni pristop uporabili pregled literature. Pregledali smo literaturo na področju življenjskega cikla upravljanja podatkov ter naredili pregled obstoječih modelov podatkovne zrelosti, na podlagi katerih smo identificirali dejavnike za oceno podatkovne zrelosti v malih in srednje velikih podjetjih.

Preiskali smo spletnne podatkovne baze: Scopus, Web of Science, Science Direct, IEEE Explore, Emerald in ProQuest. V vseh smo iskali po iskalnih nizih »data maturity«, »data maturity model«, »data maturity« AND »SME« in »data maturity model« AND »SME«. Iskali smo po vseh poljih (naslov, povzetek, ključne besede in besedilo), iskanja nismo omejili z letnicami ali vrsto publikacije. Rezultate iskanja prikazujemo v tabeli 1, iz katere je razvidno, da je področje aktualno, vendar pa na podrobnejše opredeljeno poizvedbo dobimo malo ali nič zadetkov. Iz pregledanih naslosov in poveztkov vseh prispevkov, ki smo jih našli v bazah, smo v prvem koraku v nadaljnjo obravnavo izbrali 93 prispevkov. Izloženi prispevki so se večinoma nanašali na področje zdravstva in področje odprtih vladnih podatkov, pri čemer niso posebej opredeljevali dejavnikov podatkovne zrelosti. Prispevke, ki smo jih našli v bazi Web of Science so bili vsi zajeti že v bazi Scopus. V ostalih bazah pa smo identificirali še nekaj prispevkov, ki smo jih na podlagi vsebine vključili v nadaljnjo analizo: v bazi ScienceDirect smo za podrobnejši pregled izbrali 10 prispevkov, v bazi IEEEExplore smo izbrali 12, v bazi Emerald smo jih za nadaljnji pregled izbrali 5, v podatkovni bazi ProQuest pa en dodatni prispevek. Relevantne prispevke smo izbrali na podlagi podrobnejšega vsebinskega pregleda. Izbrali smo prispevke, ki so se nanašali na modele zrelosti na področju podatkov in dejavnike, ki le-te opisujejo. Nekateri izmed prispevkov niso bili dostopni, zato smo takšne prispevke skušali poiskati preko drugih repozitorijev, kot je na primer ResearchGate.

Za izbiro končnega števila smo izključili prispevke, pri katerih celotna vsebina ni bila na voljo, niso bili napisani v angleščini ali pa niso imeli povezave z dejavniki podatkovne zrelosti. Uporabili smo tudi metodo snežne kepe in naredili nadaljnji pregled virov pri posameznih prispevkih, kar je rezultiralo v enem dodatnem viru.

Tabela 1: Rezultati iskanja ključnih besed po spletnih bazah

Iskalni niz	Scopus	Web of Science	Science Direct	IEEE Explore	Emerald	ProQuest
»data maturity«	329	70	270	16	34	149
»data maturity model«	131	16	23	8	14	11
»data maturity« AND »SME«	19	0	17	0	0	4
»data maturity model« AND »SME«	8	0	6	0	0	4

Na podlagi podrobnejšega pregleda vsebine smo identificirali 13 relevantnih prispevkov, ki vsebujejo dejavnike podatkovne zrelosti, relevantne za mala in srednje velika podjetja (slika 1).

4 Pregled modelov in dejavnikov podatkovne zrelosti

Med pregledom literature je zaznati stalen razvoj novih modelov za ocenjevanje podatkovne zrelosti (Caballero et al., 2008; Carvalho et al., 2019; Ryu et al., 2006; Spruit & Pietzka, 2015b), na podlagi katerih lahko identificiramo različne dejavnike podatkovne zrelosti. Na področju podatkovne zrelosti so v literaturi najbolj pogosto omenjeni modeli podjetij IBM (IBM, 2007), Oracle (Hornick, 2020) in Gartner (Gartner, 2018) ter modeli svetovalnih podjetij Accenture (Accenture, 2018), Deloitte (Deloitte, 2018) in Boston Consulting Group (BCG) (Baltassis et al., 2019). Temelj modelov zrelosti predstavlja metoda za ugotavljanje zrelosti razvoja računalniških programov oziroma zmožnostno zrelostni model CMM (angl. Capability Maturity Model), ki se razvija od leta 1986 naprej (Humphrey, 1988). Razvoj modela se je postopoma usmeril tudi na druga področja. Kot navaja Peng (2018) v preglednem prispevku, je leta 2014 bil objavljen model zrelosti upravljanja podatkov ki predstavlja referenčni okvir za nadaljnji razvoj modelov podatkovne zrelosti. Iz tabele 1 je razvidno, da se modeli nanašajo na različne vidike, kot je na primer vidik upravljanja podatkov (Gumain et al., 2017), vidik podatkovne pismenosti (Sternkopff in Mueller, 2018), vidik upravljanja matičnih podatkov (Spruit in Pietzka, 2015) ali pa so namenjeni velikim podjetjem (Parra et al., 2019), velikim podatkom (Comuzzi in Patel, 2016) in podobno.

Modela zrelosti, ki bi bil namenjen malim in srednje velikim podjetjem in celovito pokrival vse relevantne vidike, v literaturi nismo zasledili. Na sliki 1 so zbrani modeli podatkovne zrelosti s pripadajočimi dejavniki podatkovne zrelosti.

Dejavniki	Guangming idr., 2017	Sternkopf in Mueller, 2018	Parra idr., 2019	Loshin, 2011)	Spruit in Pietzka, 2015	Comuzzi in Pietzka, 2016	Coleman idr., 2016	(Pena idr., 2019)	Moonen idr., 2019	Blatz idr., 2018	Halper, 20017	Pillay in van der Merve, 2021	Marchildon idr., 2018
Podatkovna arhitektura	X							X		X	X		X
Varnost podatkov	X	X			X					X	X		X
Zasebnost podatkov	X										X		
Kakovost podatkov	X		X	X	X			X	X	X	X		X
Dostop do podatkov					X					X			
Konsistentnost podatkov													X
Življenski cikel podatkov	X				X				X	X			X
Vloge pri upravljanju podatkov													X
Tehnologija			X					X	X		X		
Investicije v tehnologijo													X
Revizija in poročanje													X
Uporaba in lastnišvo podatkov					X								
Ustvarjanje vrednosti s podatki													X
Organizacijska kultura						X	X					X	X
Podatkovna strategija	X					X	X	X	X		X		
Podatkovno-vodenja kultura		X							X				X
Podatkovno-vodenje odločanje			X										X
Uporaba podatkovne analitike			X						X		X		X
Kompetence zaposlenih		X	X			X	X	X	X				X
Izobraževanje deležnikov													X
Prtegnitev in zadržanje talentov													X
Podpora vodstva			X					X	X	X		X	X

Slika 1: Pregled modelov podatkovne zrelosti in pripadajočih dejavnikov

Vir: lasten.

Iz slike 1 je razvidno, da se med dejavniki podatkovne zrelosti kot ključni dejavniki podatkovne zrelosti kažejo znanja (kompetence) zaposlenih in kakovost podatkov, saj to opredeljuje največ modelov (osem od dvanaestih modelov). Poleg kakovosti moramo upoštevati tudi varnost podatkov, imeti ustrezno urejen dostop do le-teh

in zagotavljati njihovo zasebnost. Pomemben dejavnik predstavlja uporaba tehnologij, s katerimi lahko podjetje upravlja s podatki, ter opredelitev strategije. Kot ugotavlja (Coleman et al., 2016; Moonen et al., 2019; Parra et al., 2019; Peña et al., 2018; Pillay & van der Merwe, 2021) iz svojih modelov, je pri ocenjevanju podatkovne zrelosti pomembno predvsem vodstvo oziroma njegova podpora, skozi katero se razvija podatkovna kultura podjetja. Vodstvo je tisto, ki mora za uresničitev napredovanja podatkovne zrelosti sprejemati odločitve na podlagi podatkov in ne zgolj na podlagi intuicije (Parra et al., 2019; Pillay & van der Merwe, 2021; Windt et al., 2019). Kot pomembna dejavnika sta poleg že omenjenih revizija in poročanje (Cosic et al., 2012; Marchildon et al., 2018) ter ustvarjanje vrednosti s podatki (Gandhi et al., 2018; Hanafizadeh & Harati Nik, 2020). Ob tem mora organizacija upoštevati življenjski cikel podatkov (Badia, 2020; Shah et al., 2021).

Pregled dejavnikov podatkovne zrelosti je pri modelu, kot ga predlagajo Moonen in drugi (2019), pokazal, da lahko podatkovno zrelost obravnavamo z vidika organizacijskih in podatkovnih zmogljivosti, s čimer zajamemo tako oprijemljive dejavnike (npr. orodja podatkovne analitike, podatkovna arhitektura, varnost infrastrukture) kot neoprijemljive dejavnike (npr. kultura zaposlenih, znanje zaposlenih, vključenost zaposlenih) (Kljajić Borštnar & Pucihar, 2021; Moonen et al., 2019). Organizacijske zmogljivosti se nanašajo na edinstveno kombinacijo procesov, tehnologij in človeških sposobnosti, ki razlikujejo podjetje od drugih podjetij (Akaegbu & Usoro, 2017; López-Cabarcos et al., 2015). Ustvarjajo se znotraj podjetja in jih druga podjetja ali organizacije težko replicirajo (Gurkan Inan & Bititci, 2015). Podatkovne zmogljivosti pa zajemajo zmogljivosti organizacije za učinkovito upravljanje in izkoriščanje podatkov, ki jih imajo na voljo, ob uporabi podatkovnih tehnologij (Bärenfänger et al., 2015; Brinkhues et al., 2014; CDQ, 2021). Za uspešno podatkovno zrelost moramo upoštevati obe vrsti zmogljivosti.

Na podlagi pregleda literature in modelov podatkovne zrelosti, zajetih v tabeli 1, smo izmed 24 identificirali 15 dejavnikov (tabela 2), ki po našem mnenju predstavljajo podlago za oceno podatkovne zrelosti za mala in srednje velika podjetja ter se tudi v večini primerov večkrat pojavijo v modelih. Osmih dejavnikov nismo izbrali, ker so že del drugih izbranih dejavnikov širšega pomena ali pa niso zajeti v nobenem od zgornjih modelov (tabela 1).

Tabela 1: Identificirani dejavniki podatkovne zrelosti za mala in srednje velika podjetja

Dejavnik	Opredelitev (Definicija)	Avtor(ji)
Kakovost podatkov	Skupne lastnosti, ki se nanašajo na kakovost podatkov, vključujejo točnost, popolnost, zanesljivost, ustreznost in pravočasnost.	(Ryu et al., 2006); (Cai & Zhu, 2015); (Günther et al., 2019); (Ardagna et al., 2018); (Kilkenny & Robinson, 2018) (Pillay & van der Merwe, 2021); (Spruit & Pietzka, 2015a); (Peña et al., 2018); (Mouhib et al., 2020);
Organizacijska kultura	Vzpostavitev skupnih vrednot, predpostavk, prepričanj, pričakovanj, stališč in norm, ki povezujejo zaposlene v organizaciji.	(Pillay & van der Merwe, 2021); (Comuzzi & Patel, 2016); (Coleman et al., 2016);
Podatkovno-vodena kultura	Vzorec vedenja in praks skupine ljudi, ki si deli prepričanje, da imetje, razumevanje in uporaba (določene vrste) podatkov in informacij predstavlja ključno vlogo pri uspehu njihovih organizacij.	(Kiron et al., 2013); (Chatterjee et al., 2021); (Anderson, 2015); (Berntsson Svensson & Taghavianfar, 2020); (Rogers, 2020);
Podatkovna arhitektura	Podatkovna arhitektura omogoča zbiranje, shranjevanje, prenos, integracijo in upravljanje podatkov. Predstavlja logično in fizično strukturo podatkovnih virov in sistemov za upravljanje s podatki v organizaciji.	(Sherman, 2015); (Ulrich, 2010); (Kaidalova et al., 2018); (TOGAF, 2018)
Podatkovno-vodeno odločanje	Podatkovno-vodeno odločanje se nanaša na sprejemanje odločitev na podlagi analize podatkov in ne zgolj na podlagi intuicije.	(Pillay & van der Merwe, 2021); (Provost & Fawcett, 2013); (Stobierski, 2019); (Rejkumara et al., 2020);
Vodstvo	Vodstvo določi smer razvoja za doseganje večje podatkovne zrelosti, zna postaviti prava vprašanja, se zaveda pomembnosti podatkov in sprejemanja odločitev na podlagi podatkov in ozavešča zaposlene o vrednosti podatkov skozi nenehno komunikacijo, jih pri tem motivira in podpira. S tem pa se ustvarja kultura, ki temelji na podatkih.	(Windt et al., 2019); (Pillay & van der Merwe, 2021); (Coleman et al., 2016); (Peña et al., 2018); (Limpeeticharoenchot et al., 2020); (Mouhib et al., 2020);

Dejavnik	Opredelitev (Definicija)	Avtor(ji)
Podatkovne kompetence (včasih tudi podatkovna pismenost)	Nabor spremnosti, znanj in sposobnosti iskanja, razumevanja, kritičnega ocenjevanja, uporabe, analiziranja, predstavitev in argumentacije podatkov z namenom povezovanja podatkov in ustvarjanja znanja. Podatkovne kompetence včasih opredeljujemo s terminom podatkovna pismenost.	(Pillay & van der Merwe, 2021); (Comuzzi & Patel, 2016); (Coleman et al., 2016); (Peña et al., 2018); (Limpeetcharoenchot et al., 2020); (Mouhib et al., 2020);
Podatkovna strategija	Podatkovna strategija določa obseg in cilj upravljanja podatkov. Gre za podroben načrt, kako bo podjetje s podatki upravljalo, kakšen cilj želi pri tem dosegči in kako bo podatke najbolje izkoristilo v smeri izpolnjevanja organizacijske vizije in poslanstva.	(Comuzzi & Patel, 2016); (Coleman et al., 2016); (Peña et al., 2018); (Mouhib et al., 2020);
Življenjski cikel podatkov	Življenjski cikel podatkov opredeljuje časovno obdobje obstoja podatka v informacijskem sistemu podjetja. Pri tem gre vsak podatek skozi posamezne korake (tj. zbiranje, hramba, čiščenje podatkov, priprava in analiza, arhiviranje in uničenje podatkov).	(Spruit & Pietzka, 2015a); (Mouhib et al., 2020); (Badia, 2020); (Shah et al., 2021);
Dostop do podatkov	Nivo dostopa do podatkov (kdo ima dostop do podatkov, ali so podatki odprtji ali zaščiteni, ali so vpeljani standardi, ki opredeljujejo dostop do podatkov).	(Spruit & Pietzka, 2015a);
Varnost podatkov	Zaščita podatkov pred nepooblaščenim dostopom, vdorom v informacijski sistem, odtujitvijo (krajo) podatkov in zlorabo ter ostalimi varnostnimi incidenti.	(Spruit & Pietzka, 2015a);
Zasebnost podatkov	Opredeljuje politike, prakse in pravila, ki v organizaciji opredeljujejo zbiranje in upravljanje osebnih	(Marchildon et al., 2018);

Dejavnik	Opredelitev (Definicija)	Avtor(ji)
	podatkov. Najbolj znana je uredba o upravljanju osebnih podatkov GDPR, ki se je začela uporabljati z letom 2018.	
Revizija in poročanje	Revizija zajema pregled podatkov o finančnih izkazih podjetja. Poročanje pa zajema pripravo poročil za namen poročanja podatkov o finančnih računih.	(Marchildon et al., 2018); (Cosic et al., 2012); (European Comission, b. d.);
Ustvarjanje vrednosti s podatki	Ustvarjanje vrednosti s podatki (poznamo tudi kot monetizacija podatkov) se nanaša na različne pristope, s katerimi lahko ustvarjamo dodano vrednost podjetja preko izkoriščanja podatkov.	(Almazmomi et al., 2021); (Babu et al., 2021); (Lehrer et al., 2018); (Spiekermann, 2019); (Hanafizadeh & Harati Nik, 2020); (Gandhi et al., 2018);
Tehnologija	Digitalne tehnologije, ki podjetju zagotavljajo zbiranje, shranjevanje, prenos podatkov in pridobivanje znanja iz podatkov.	(Pillay & van der Merwe, 2021); (Comuzzi & Patel, 2016); (Coleman et al., 2016); (Peña et al., 2018); (Limpeetcharoenchot et al., 2020); (Mouhib et al., 2020).

V nadaljevanju bomo posamezne dejavnike podrobnejše opisali.

- Kakovost podatkov

Neprestano naraščanje in generiranje podatkov iz različnih virov (poslovni informacijski sistemi podjetja, senzorji naprav, podatki družbenih medijev) ter kasnejša analiza le-teh omogoča med drugim lažje razumevanje potreb strank, izboljšanje kakovosti storitev, napovedovanje trendov na trgih, preprečevanje tveganj ter podporo pri sprejemanju odločitev (Cai & Zhu, 2015; Günther et al., 2019). Za to pa potrebujemo kakovostne podatke (Alshikhi & Abdullah, 2018; Haug et al., 2011; Price & Shanks, 2008; Ramasamy & Chowdhury, 2020).

Na podlagi pregleda modelov podatkovne zrelosti (tabela 1) smo ugotovili, da je kakovost podatkov temeljni dejavnik, ki ga moramo upoštevati za zagotovitev podatkovne zrelosti organizacije. Dejavnik »kakovost podatkov« se namreč ponovi pri osmih od dvanajstih modelov. Ključne dimenzije, ki opredeljujejo kakovost

podatkov, vključujejo natančnost, popolnost, doslednost, časovnost in relevantnost (Günther et al., 2019; Ryu et al., 2006). **Natančnost podatkov** opredeljuje pravilnost podatkov in njihovo zanesljivost, torej: da ti ne vsebujejo napak, da odražajo resnično stanje in da so nedvoumni (Cai & Zhu, 2015). Pri **popolnosti podatkov** ocenjujemo celovitost podatkov, torej: ali podjetje razpolaga z vsemi potrebnimi podatki ali so morda manjkajoče vrednosti podatkov (Ardagna et al., 2018). **Doslednost podatkov** zagotavlja, da so podatki predstavljeni v enaki obliki in tudi združljivi s prejšnjimi podatki (Cai & Zhu, 2015; Wang & Strong, 1996). **Časovnost** (angl. timeliness) opredeljuje starost podatkov – koliko časa so ti že v uporabi in kdaj so bili nazadnje posodobljeni (Günther et al., 2019; Wang & Strong, 1996). Pomembno je, da s kakovostjo zagotovimo tudi **relevantnost podatkov**, ki zajema oceno, ali so razpoložljivi podatki, ki jih želimo uporabiti, primerni za nameravano uporabo in zadovoljujejo potrebe uporabnikov (Cai & Zhu, 2015; Günther et al., 2019).

- Kultura podjetja (organizacijska kultura in podatkovna kultura)

Če želimo spodbuditi razmišljanje o pomembnosti učinkovitega upravljanja in obvladovanja podatkov, mora podjetje vzpostaviti kulturo (Anderson, 2015), skozi katero se bo dvignil nivo zaposlenih pri uresničevanju digitalne zrelosti tudi pri podatkih, kar pa je tudi pogoj za podatkovno-vodeno organizacijo oziroma podjetje (Berntsson Svensson & Taghavianfar, 2020). Da bi lahko opredelili podatkovno-vodeno kulturo, moramo najprej opredeliti organizacijsko kulturo. Avtorja (Kremser & Brunauer, 2019) namreč ugotovljata, da je podatkovno-vodena kultura del organizacijske kulture. Organizacijska kultura tako predstavlja osnovo za razvoj podatkovno-vodene kulture. Organizacijsko kulturo lahko opredelimo kot kompleksen niz vrednot, preričanj in predpostavk, ki opredeljujejo način, kako podjetje vodi svoje poslovanje. Medtem ko podatkovno-vodena kultura opredeljuje vzorec vedenja in praks skupine ljudi, ki si deli preričanje, da imetje, razumevanje in uporaba (določene vrste) podatkov in informacij predstavlja ključno vlogo pri uspehu njihovih organizacij (Kiron et al., 2013).

Ker je med literaturo (Anderson, 2015; Berntsson Svensson & Taghavianfar, 2020; Chatterjee et al., 2021; Rogers, 2020) zaznati vse večji pomen podatkovne kulture, smo podatkovno kulturo ločili od organizacijske kulture in opredelili dejavnike, s katerimi lahko opredelimo podatkovno kulturo posebej. V prvi vrsti je pomemben

dejavnik, ki opredeljuje zavedanje zaposlenih glede pomembnosti podatkov – torej: ali podatke vidijo le kot vir, s katerim izvajajo poslovanje (Comuzzi & Patel, 2018), ali jih razumejo kot strateški vir, ki ga je možno uporabiti za razvoj ali obogatitev izdelkov in storitev (Gandhi et al., 2018; Hanafizadeh & Harati Nik, 2020), in tako s pomočjo podatkov ustvarjajo dodano vrednost v podjetju.

– Podatkovna arhitektura

Podatkovna arhitektura predstavlja logično in fizično strukturo podatkovnih virov in sistemov za upravljanje s podatki v organizaciji (tako imenovani okvir TOGAF) (Kaidalova et al., 2018; TOGAF, 2018). Je del arhitekture podjetja (angl. enterprise architecture), ki zajema modele, politike, pravila in standarde, ti pa predpisujejo zbiranje, shranjevanje, prenos, integracijo in uporabo podatkov v organizaciji. Cilj podatkovne arhitekture je prevesti poslovne zahteve v podatkovne in sistemskе zahteve in upravljalni tok podatkov skozi poslovne procese. Mnoge organizacije se na poti digitalne preobrazbe soočijo z izzivom premisleka o podatkovni arhitekturi, saj so urejeni podatki predpogoji za uspešno implementacijo podatkovne analitike ali umetne inteligence (Ghosh, 2020). Pomembnost podatkovne arhitekture na poti digitalne preobrazbe in preobrazbe v podatkovno-vodeno podjetje poudarjajo tudi poročila raziskovalno-svetovalnih organizacij (Blumberg et al., 2017; Castro et al., 2020). Podatkovna arhitektura se torej nanaša tako na upravljanje podatkov kot tudi na fizično infrastrukturo, s katero podatke zajemamo, hranimo in tako dalje.

– Podatkovno-vodeno odločanje

Podjetjem, ki želijo bolje izkoristiti svoje podatke in s tem dvigniti svojo podatkovno zrelost, predstavlja pomemben dejavnik tudi podatkovno-vodeno odločanje oziroma sprejemanje odločitev, ki temeljijo na podatkih (Shah et al., 2012; Windt et al., 2019). Osnovo vsakega informacijskega sistema predstavljajo podatki, kjer iz podatkov nadalje oblikujemo informacije, te pa so osnovni vir za sprejemanje odločitev (Mintzberg, 1990). Avtorji (Rejkumar et al., 2020) podatkovno-vodeno odločanje opredeljujejo kot pristop, ki ga podjetja in managerji sprejmejo pri odločanju na podlagi preverljivih podatkov. Provost in Fawcett (2013) pa to opredeljujeta kot prakso sprejemanja odločitev na podlagi analize podatkov in ne zgolj na podlagi intuicije. V procesu odločanja lahko uporabimo sisteme za podporo odločanju, ki temeljijo na uporabi modelov (Power & Sharda, 2007) ali pa na uporabi

podatkov (Power, 2008). Medtem ko v prvem primeru za razvoj modelov skrbijo strokovnjaki s svojim razumevanjem sistemov in poznavanjem metod in notacij za razvoj modelov, se v drugem primeru zanašamo na podatke, s katerimi gradimo modele (Power & Sharda, 2007). Glavna kritika modelov, ki jih gradimo ljudje, je zaznava in razumevanje realnosti (razumevanje delovanja sistema) in sposobnost razvoja modela, vendar pa podatkovno gnani modeli tudi niso brezhibni. Temeljijo namreč na preteklih dejstvih, podatkih in odločitvah, ki hranijo tudi naše napake, zaznave in predsdokte (Kljajic Borštnar, 2022). Iz tega razloga je potrebno k odločanju pristopiti s kritičnim premislekom glede na dano situacijo in potrebe oziroma s povezovanjem podatkovnih in modelnih pristopov (Power & Sharda, 2007).

– Vodstvo

Poglavitén dejavnik, ki vpliva na spodbuditev in nadaljnje uresničevanje podatkovne zrelosti podjetja, je vodstvo (Windt et al., 2019). Vodstvo mora biti spodbujevalec sprememb, se zavedati pomembnosti podatkov in sprejemanja odločitev, ki so utemeljene na podatkih, to pa naprej prenašati na svoje zaposlene skozi nenehno komunikacijo, jih pri tem podpirati in motivirati (Cosic et al., 2012; Windt et al., 2019). S tem se nadalje gradi kultura organizacije (Waller, 2020), ki temelji na zavedanju pomembnosti podatkov in uporabi podatkov kot glavnega vira pri poslovanju (Coleman et al., 2016). Pri doseganju večje podatkovne zrelosti sta pomembna odnos vodstva (Pugna et al., 2019) (kako gleda na vlogo podatkov – ali so ključni dejavnik za doseg in uresničitev poslovnih ciljev) in podpora vodstva (Mikalef et al., 2019) (ali vodstvo podpira zaposlene za boljše upravljanje podatkov in ustvarjanje vrednosti, ki jo podatki lahko prinesejo). Vodstvo mora za dosego podatkovne zrelosti opredeliti tudi načrt glede upravljanja podatkov in tako postaviti ustrezeno podatkovno strategijo (Mikalef et al., 2019). Da bi mala in srednje velika podjetja lahko zagotovila celovito oceno podatkovne zrelosti, moramo upoštevati tudi agilnost vodstva pri odzivanju na spremembe (kako hitro se vodstvo odziva na spremembe in se jim prilagaja) in način vodenja, ki je lahko zgolj hierarhičen ali sodelovalen (Kljajic Borštnar & Pucihar, 2021).

– Znanja (kompetence) zaposlenih

Med človeškimi viri smo na podlagi pregledanih modelov podatkovne zrelosti (v tabeli 1) kot pomemben dejavnik, s katerim lahko ocenimo podatkovno zrelost podjetja, identificirali tudi znanja zaposlenih. To se je pokazalo pri osmih od dvanajstih modelov. Mala in srednje velika podjetja so z viri omejena, tako s finančnimi kot kadrovskimi (Bookelmann & Sneep, b. d.; Zimmermann, 2016), zato so pogosto omejena na razvoj lastnih znanj. Za napredovanje in doseganje večje podatkovne zrelosti je zato pomembno, da imajo zaposleni razvite sposobnosti iskanja, razumevanja, kritičnega ocenjevanja, uporabe, analiziranja, predstavitev in argumentacije podatkov, da lahko podatke med seboj povezujejo in ustvarjajo znanje (Sternkopf & Mueller, 2018). Poleg tega je pomemben dejavnik tudi vložek v usposabljanje zaposlenih, ki opredeljuje, koliko podjetje vlaga v izboljšanje podatkovnih kompetenc zaposlenih.

– Podatkovna strategija

Del poslovanja vsakega podjetja predstavlja jasno zastavljena strategija (Cordeiro, 2013). Dobro načrtovana strategija podjetjem omogoča, da so lahko pri poslovanju od svoje konkurence uspešnejša in se lažje spopadajo s spremembami okolja (Parnell, 2013; Turner & Endres, 2017). Med literaturo lahko zaznamo več opredelitev, ki se nanašajo na strategijo podjetja. Chandler (1962, str. 13) strategijo podjetja opredeljuje kot določitev osnovnih dolgoročnih ciljev podjetja ter opredelitev smeri delovanja in razporeditev sredstev, potrebnih za uresničitev teh ciljev, Porter (1980, str. 24) pa strategijo opredeljuje kot določitev formule, kjer podjetje določi, kako bo konkuriralo, kakšni bodo njegovi cilji in kakšne politike bodo potrebne za uresničitev teh ciljev. Kot ugotovljata (Aiken & Gorman, 2013), za uspešno načrtovanje in napredovanje strategije podjetja potrebujemo podatke, s katerimi merimo doseganje ciljev strategije podjetja, uporaba podatkov kot strateškega vira pa nadalje omogoča razvoj podatkovne strategije, ki je pomembna za razvoj podatkovno zrelega podjetja.

Davenport in DalleMule (2017) opredeljujeta podatkovno strategijo kot način organiziranja, upravljanja, analiziranja in razporejanja podatkov oziroma informacij kot sredstev podjetja, ki se ustvarjajo tekom izvajanja poslovnih procesov podjetja (Eroğlu & Çakmak, 2018). Grossman (2018) na primer podatkovno strategijo

opredeljuje kot dolgoročne odločitve, ki jih organizacija sprejme, in se nanašajo na to, kako podjetje uporablja svoje podatke za izvajanje dejanj, ki izpolnjujejo njeno organizacijsko vizijo in poslanstvo. Podatkovna strategija se torej razvija s pomočjo dobro opredeljenega upravljanja s podatki, jasnih ciljev in načel ter s pomočjo jasnih vlog in odgovornosti, ne glede na to, ali so cilji dolgoročni ali kratkoročni (Al Omari et al., 2021). Pri tem ločimo dva pristopa – defenzivni in ofenzivni pristop (Davenport & DalleMule, 2017). Medtem ko je defenzivni pristop usmerjen na večjo previdnost ravnanja s podatki in omejevanje tveganj, kar zajema zagotavljanje verodostojnosti podatkov in skladnost s predpisi (kot je na primer skladnost z uredbo o varstvu podatkov (GDPR)), uporabo analitike za odkrivljanje in omejevanje goljufij ter sisteme za preprečevanje kraje podatkov, je ofenzivni pristop usmerjen na povečevanje prihodkov, ustvarjanje dobička in zadovoljstva strank. Za uspešno podatkovno zrelost sta pomembna oba (Davenport & DalleMule, 2017).

– Življenski cikel podatkov

Zaradi stalnega naraščanja podatkov postaja upravljanje le-teh vedno bolj zapleteno (El Arass & Souissi, 2018). Za učinkovito upravljanje podatkov predstavlja pomemben del življenski cikel podatkov, ki opredeljuje obstoj podatka in posamezne faze, skozi katere gre vsak podatek tekom njegovega obstoja (zbiranje, shranjevanje, čiščenje podatkov, priprava in analiza, arhiviranje in uničenje podatkov) (Shah et al., 2021). Prva faza zajema zbiranje podatkov, kjer podjetje najprej zbere podatke iz različnih podatkovnih virov (informacijski sistemi podjetja, družbeni mediji, repozitoriji odprtih podatkov, senzorji naprav) ali pa jih podjetje ustvari tekom poslovanja (Baesens et al., 2016). Sledi shranjevanje podatkov, pri čemer je odvisno od podjetja, katere podatke bo shranilo in na katero mesto (uporaba podatkovne baze, uporaba oblaka kot medija za shranjevanje) (Stobierski, 2019). Naslednji fazi sta čiščenje podatkov in priprava podatkov za analizo (Badia, 2020). Čiščenje podatkov zajema pregled podatkov ter odstranitev napačnih in podvojenih vrednosti podatkov. Pri pripravi podatkov pred analizo podatkom določimo ustrezno obliko (npr. tabelarična oblika, številske vrednosti) (Badia, 2020). Podjetje nato podatke analizira, na podlagi analiziranih podatkov pridobi informacije in ustvari znanje, pridobljeno znanje pa predstavlja osnovo za sprejemanje odločitev (Abbas et al., 2016; El Arass, & Souissi, 2018). Zadnji fazi predstavlja arhiviranje podatkov z namenom, če bi le-te kdaj ponovno potrebovali, in uničenje podatkov,

kjer podatke uničimo, če nam ne prinašajo več dodane vrednosti in so odslužili svojemu namenu (El Arass, & Souissi, 2018).

– Varnost podatkov

Pri upravljanju podatkov morajo podjetja zagotavljati tudi ustrezeno varnost podatkov. Kot izpostavljata (Comuzzi & Patel, 2016), je varnost podatkov pogosto spregledan dejavnik, zato je pomembno, da podjetja upoštevajo tudi ta dejavnik, če želijo svoje podatke ustrezeno zaščititi (na primer pred nepooblaščenim dostopom). Varnost podatkov lahko opredelimo kot način zaščite podatkov pred neželenimi varnostnimi incidenti (Spruit & Pietzka, 2015b). Varnostni incidenti so lahko povezani z odpovedjo strojne ali programske opreme, s čimer lahko izgubimo podatke, vdorom v informacijski sistem in odtujitvijo (krajo) podatkov (Hammouchi et al., 2019; Spruit & Pietzka, 2015b) ter zlorabo podatkov (Šverko, 2009). Pred tem se podjetja lahko zaščitijo z uporabo sistemov za zaznavanje napadov (angl. Intrusion Detection System), ki podjetjem z zaznavanjem napadov omogočijo obrambo pred zlonamerno uporabo računalniških sistemov in jih o tem obvestijo (Tan et al., 2014).

– Tehnologija

Hitre spremembe okolja (spremembe v konkurenči, povpraševanju, tehnologiji) zahtevajo od organizacij, da se hitro odzovejo in prilagodijo (Teichert, 2019). Digitalne tehnologije, kot so družbeni mediji, računalništvo v oblaku, vgrajene naprave, 3D-tisk, internet stvari in umetna inteligenco, ustvarjajo vse več podatkov, s katerimi moramo učinkovito upravljati. V kontekstu podatkovne zrelosti predstavljajo digitalne tehnologije pomemben dejavnik, s katerimi lahko zajemamo, obdelujemo in upravljamo podatke. Med digitalnimi tehnologijami je še posebej pomembna uporaba podatkovne analitike, na podlagi katere lahko iz podatkov pridobimo nova spoznanja, razvijamo storitve in izdelke, ki so strankam bolj prilagojeni, in podpremo odločitve, da so te utemeljene na podatkih (Król & Zdonek, 2020; Qin, 2014). V tej smeri se razvijajo tudi modeli podatkovne zrelosti, ki so namenjeni oceni zrelosti podatkovne analitike v podjetju, na primer model DAMAF avtorjev (Gökalp et al., 2021), s katerim lahko ocenimo, ali ima podjetje podatkovno analitiko že v uporabi in zakaj jo uporablja.

– Ustvarjanje vrednosti s podatki

Na koncu je pomembno, da podjetja skozi uporabo podatkov in njihovo upravljanje ustvarjajo dodano vrednost podjetja. Ustvarjanje vrednosti s podatki je v literaturi poznano pod terminom »monetizacija podatkov« in se nanaša na različne pristope, s katerimi lahko ustvarjamo dodano vrednost podjetja preko izkoriščanja podatkov (Gandhi et al., 2018; Hanafizadeh & Harati Nik, 2020). Bodisi je to z uporabo podatkovnih tržnic, kjer proti plačilu podatke kupimo in pridobimo koristne informacije za nadaljnje poslovanje ali pa lastne podatke preko tržnice prodamo (Spiekermann, 2019); bodisi uporabimo pristop podatkovnega inoviranja, kjer s pomočjo podatkov, ki jih imamo v podjetju, izboljšamo procese, izdelke, storitve ali ustvarimo nove (Babu et al., 2021; Lehrer et al., 2018); lahko pa z uporabo podatkov zmanjšamo operativne stroške poslovanja (Gandhi et al., 2018) ali povečamo prihodke na podlagi podatkovno-obogatenih izdelkov in storitev (Wixom & Ross, 2017).

5 Diskusija in zaključki

V zadnjih letih je zaznati vedno večje naraščanje podatkov, ki se generirajo iz različnih podatkovnih virov (poslovni informacijski sistemi podjetij, podatki, zajeti preko družbenih medijev, mobilne naprave, podatki senzorjev naprav, repozitoriji odprtih podatkov) (Baesens et al., 2016). Z naraščajočim številom podatkov je vedno bolj pomembno njihovo upravljanje, ki pa je tudi vedno bolj kompleksno (El Arass & Souissi, 2018). Zato je pomembno, da je sodobna organizacija poleg obvladovanja digitalnih tehnologij sposobna upravljati tudi s podatki, na podlagi katerih lahko oblikujemo informacije, iz informacij izluščimo znanje, ki ga prej še nismo imeli (Abbas et al., 2016). Na podlagi tako pridobljenega znanja pa sprejemamo dobro informirane odločitve, ki so podprte s podatki. Tako mora biti vsaka organizacija zmožna zbiranja, shranjevanja, preoblikovanja podatkov in poročanja, ob tem pa sposobna izgradnje procesov, ki zahtevajo odločanje na podlagi podatkov (Rogers, 2020), s čimer se kaže vse večja potreba po razvoju digitalne zrelosti organizacije tudi pri podatkih in s tem dobre podatkovne zrelosti.

V prispevku smo obravnavali problem podatkovne zrelosti. Skozi pregled literature obstoječih modelov podatkovne zrelosti smo opredelili dejavnike, s katerimi lahko ocenimo podatkovno zrelost malih in srednje velikih podjetijh. Pregled literature je pokazal, da zajema podatkovna zrelost več dejavnikov (kakovost podatkov, varnost podatkov, kultura podjetja, odločanje, znanja zaposlenih idr.), zato podatkovne zrelosti ne moremo obravnavati le z vidika enega dejavnika, s katerim lahko zagotovimo celovito oceno podatkovne zrelosti. Ocena podatkovne zrelosti je pomembna, saj podjetjem omogoča boljše razumevanje vloge podatkov in njihovega vpliva z različnih vidikov. Z vpogledom v stanje podatkovne zrelosti imajo možnosti sprejeti boljše odločitve o vlaganjih v razvoj tehnologije, procese, zaposlene, ki bodo usklajeni s strategijo podjetja. Boljše odločanje vodi do hitrejših sprememb v podjetju, nižjih stroškov, hitrejših delovnih procesov.

Na podlagi pregleda literature ugotavljamo, da trenutni modeli za oceno podatkovne zrelosti malim in srednje velikim podjetjem niso posebej prilagojeni. Zato smo v prispevku izbrali in opredelili dejavnike podatkovne zrelosti, ki so relevantni za mala in srednje velika podjetja in jih bo moč uporabiti za razvoj celovitega večkriterijskega modela za oceno podatkovne zrelosti. V nadaljevanju bomo izbrane dejavnike validirali z izvedbo intervjujev v izbranih MSP, nato pa bo sledil razvoj hierarhičnega večkriterijskega modela, ki bo prilagojen malim in srednje velikim podjetjem.

Zahvala

Raziskava je bila podprtta s strani Javne agencije za raziskovalno dejavnost Republike Slovenije v okviru programa P5-0018 – Sistemi za podporo odločanju v digitalnem poslovanju in programa usposabljanja za mladega raziskovalca številka 54752-0586-21.

Literatura

- Abbas, A., Sarker, S., Chiang, R. H. L., & Lindner, C. H. (2016). Big Data Research in Information Systems: Toward an Inclusive Research Agenda. *Journal of the Association for Information Systems*, 17(2), 1–32. https://aisel.aisnet.org/jais/big_data_info_systems.pdf
- Accenture. (2018). *Becoming a data-driven enterprise: Data Industrialization*. <https://www.accenture.com/us-en/insights/technology/data-industrialization>
- Aiken, P., & Gorman, M. (2013). Developing Your Organization's Data Leveraging Capabilities. V *The Case for the Chief Data Officer: Recasting the C-Suite to Leverage Your Most Valuable Asset*. Morgan Kaufmann.
https://books.google.si/books?id=h7vOSdWVV5UC&pg=PA19&hl=sl&source=gbs_toc_r&cad=3#v=onepage&q&f=false
- Akaegbu, J. B., & Usoro, A. A. (2017). THE PLACE OF ORGANISATIONAL CAPABILITIES IN STRATEGY FORMULATION AND IMPLEMENTATION: AN EXPLORATORY

- ANALYSIS. *GLOBAL JOURNAL OF SOCIAL SCIENCES*, 16, 39–48.
<https://doi.org/10.4314/gjss.v16i1.5>
- Al Omari, H., Barham, S., & Qusef, A. (2021). Data Strategy and Its Impact on Open Government Data Quality. *2021 International Conference on Information Technology (ICIT)*, 648–653.
<https://doi.org/10.1109/ICIT52682.2021.9491766>
- Almazmomi, N., Ilmudeen, A., & Qaffas, A. A. (2021). The impact of business analytics capability on data-driven culture and exploration: achieving a competitive advantage. *Benchmarking*, 1–20.
<https://doi.org/10.1108/BIJ-01-2021-0021>
- Alshikhi, O. A., & Abdullah, B. M. (2018). INFORMATION QUALITY: DEFINITIONS, MEASUREMENT, DIMENSIONS, AND RELATIONSHIP WITH DECISION MAKING. *European Journal of Business and Innovation Research*, 6(5), 36–42.
<https://www.eajournals.org/wp-content/uploads/Information-Quality-Definitions-Measurement-Dimensions-and-Relationship-with-Decison-Making-6.pdf>
- Anderson, C. (2015). Creating a Data-Driven Organization: Practical Advice from the Trenches. V T. McGovern (Ur.), O'Reilly (First). O'Reilly Media, Inc.
https://books.google.si/books?hl=en&lr=&id=MVpDCgAAQBAJ&oi=fnd&pg=PR2&dq=driven+organization&ots=Ij157j1YCV&sig=mdFzH1I90XUzGdBvtgH7SWhAFG0&redir_esc=y#v=onepage&q=data-driven organization&f=false
- Anshari, M., Almunawar, M. N., Lim, S. A., & Al-Mudimigh, A. (2019). Customer relationship management and big data enabled: Personalization & customization of services. *Applied Computing and Informatics*, 15(2), 94–101.
<https://doi.org/10.1016/J.ACI.2018.05.004>
- Ardagna, D., Cappiello, C., Samá, W., & Vitali, M. (2018). Context-aware data quality assessment for big data. *Future Generation Computer Systems*, 89, 548–562.
<https://doi.org/https://doi.org/10.1016/j.future.2018.07.014>
- Babu, M. M., Rahman, M., Alam, A., & Dey, B. L. (2021). Exploring big data-driven innovation in the manufacturing sector: evidence from UK firms. *Annals of Operations Research*, 1–28.
<https://doi.org/10.1007/S10479-021-04077-1>
- Badia, A. (2020). The Data Life Cycle. V A. Badia (Ur.), *SQL for Data Science: Data Cleaning, Wrangling and Analytics with Relational Databases* (str. 1–29). Springer International Publishing.
https://doi.org/10.1007/978-3-030-57592-2_1
- Baesens, B., Bapna, R., Marsden, J. R., Vanthienen, J., & Zhao, J. L. (2016). TRANSFORMATIONAL ISSUES OF BIG DATA AND ANALYTICS IN NETWORKED BUSINESS. *MIS Quarterly*, 40(4), 807–818.
<https://pdfs.semanticscholar.org/0fc1/5b775475b97c5e29d1422af5df6afe8e446.pdf>
- Baltassis, E., Gourevitch, A., & Quarta, L. (2019). *Good Data Starts with Great Governance*.
https://image-src.bcg.com/Images/BCG-Good-Data-Starts-with-Great-Governance-Nov-2019-R_tcm9-233456.pdf
- Bärenfänger, R., Otto, B., & Gizanis, D. (2015). *Business and Data Management Capabilities for the Digital Economy*.
https://www.alexandria.unisg.ch/244405/1/White Paper Capabilities for the Digital Economy 21_rbac_v1.0.pdf
- Begg, C., & Caira, T. (2012). Exploring the SME Quandary: Data Governance in Practise in the Small to Medium-Sized Enterprise Sector. *Electronic Journal of Information Systems Evaluation*, 15(1), 3–13.
<https://academic-publishing.org/index.php/ejise/article/view/237>
- Berntsson Svensson, R., & Taghavianfar, M. (2020). Toward Becoming a Data-Driven Organization: Challenges and Benefits. V F. Dalpiaz, J. Zdravkovic, & P. Loucopoulos (Ur.), *Research Challenges in Information Science* (str. 3–19). Springer International Publishing.
https://doi.org/10.1007/978-3-030-50316-1_1
- Blumberg, S., Bossert, O., Grabenhorst, H., & Soller, H. (2017). Why you need a digital data architecture to build a sustainable digital business | McKinsey & Company. *McKinsey & Company*, 1–7.
- Bookelmann, M., & Sneep, R. (b. d.). *Desk study - Futures by design - Increasing the data maturity of SMEs*.

- Pridobljeno 21. januar 2022., od <https://elcidata.be/sites/default/files/realisations/WP4 - Increasing the Data Maturity of SMEs%5B17235%5D.pdf>
- Brinkhues, R. A., Carlos Gastaud Maçada, A., & D'Agostini Oliveira Casalinho, G. (2014). Information Management Capabilities: Antecedents And Consequences. *Twentieth Americas Conference on Information Systems*, 1–11. https://www.researchgate.net/profile/Rafael-Brinkhues/publication/263272671_Information_Management_Capabilities_Antecedents_An_d_Consequences_Completed_Research_Paper/links/564a11b908ae44c7a28d9146/Information-Management-Capabilities-Antecedents-And-Conseq
- Caballero, I., Caro, A., Calero, C., & Piattini, M. (2008). IQM3: Information Quality Management Maturity Model. *Journal of Universal Computer Science*, 14(22), 3658–3685. https://www.jucs.org/jucs_14_22/iqm3_information_quality_management/jucs_14_22_3658_3685_caballero.pdf
- Cai, L., & Zhu, Y. (2015). The Challenges of Data Quality and Data Quality Assessment in the Big Data Era. *Data Science Journal*, 14, 1–10. <https://doi.org/10.5334/dsj-2015-002>
- Carillo, K. D. A. (2017). Let's stop trying to be "sexy" – preparing managers for the (big) data-driven business era. *Business Process Management Journal*, 23(3), 598–622. <https://doi.org/10.1108/BPMJ-09-2016-0188>
- Carvalho, J. V., Rocha, Á., Vasconcelos, J., & Abreu, A. (2019). A health data analytics maturity model for hospitals information systems. *International Journal of Information Management*, 46, 278–285. <https://doi.org/10.1016/j.ijinfomgt.2018.07.001>
- Castro, A., Machado, J., Roggendorf, M., & Soller, H. (2020). *How to build a data architecture to drive innovation-today and tomorrow | McKinsey*. <https://www.mckinsey.com/business-functions/mckinsey-digital/our-insights/how-to-build-a-data-architecture-to-drive-innovation-today-and-tomorrow>
- Cattaneo, G., Micheletti, G., Glennon, M., La Croce, C., & Mitta, C. (2020). *The European Data Market Monitoring Tool: Key Facts & Figures, First Policy Conclusions, Data Landscape and Quantified Stories*. <https://doi.org/10.2759/72084>
- CDQ. (2021). *Data Excellence Model*. <https://www.cc-cdq.ch/data-excellence-model>
- Chandler, A. D. J. (1962). *Strategy and Structure: Chapters in the History of the Industrial Enterprise*. <https://s3.amazonaws.com/arena-attachments/705027/a973f694aaaee073aeb1cfce037f3b11.pdf>
- Chanias, S., & Hess, T. (2016). *How digital are we? Maturity models for the assessment of a company's status in the digital transformation*. https://www.wim.bwl.uni-muenchen.de/download epub/mreport_2016_2.pdf
- Chatterjee, S., Chaudhuri, R., & Vrontis, D. (2021). Does data-driven culture impact innovation and performance of a firm? An empirical examination. *Annals of Operations Research*. <https://doi.org/10.1007/s10479-020-03887-z>
- Ciampi, F., Demi, S., Magrini, A., Marzi, G., & Papa, A. (2021). Exploring the impact of big data analytics capabilities on business model innovation: The mediating role of entrepreneurial orientation". *Journal of Business Research*, 123, 1–13. <https://doi.org/10.1016/j.jbusres.2020.09.023>
- Ciuriak, D. (2018). The Economics of Data: Implications for the Data-Driven Economy. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3118022>
- Coleman, S., Göb, R., Manco, G., Pievatolo, A., Tort-Martorell, X., & Reis, M. S. (2016). How Can SMEs Benefit from Big Data? Challenges and a Path Forward. *Quality and Reliability Engineering International*, 32(6), 2151–2164. <https://doi.org/10.1002/QRE.2008>
- Comuzzi, M., & Patel, A. (2016). How organisations leverage Big Data: a maturity modl. *Industrial Management & Data Systems*, 116(8), 1468–1492. <https://doi.org/10.1108/IMDS-12-2015-0495>
- Cordeiro, W. P. (2013). Small Businesses Ignore Strategic Planning at their Peril. *Academy of Business Research Journal*, 3, 22–30. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2519720
- Correani, A., De Massis, A., Frattini, F., Petruzzelli, A. M., & Natalicchio, A. (2020). Implementing a Digital Strategy: Learning from the Experience of Three Digital Transformation Projects.

- California Management Review*, 62(4), 37–56. <https://doi.org/10.1177/0008125620934864>
- Cosic, R., Shanks, G., & Maynard, S. (2012). Towards a business analytics capability maturity model. *ACIS 2012 : Proceedings of the 23rd Australasian Conference on Information Systems*, 1–11. <https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1013&context=acis2012>
- Davenport, T. H., & DalleMule, L. (2017). The 2 Types of Data Strategies Every Company Needs. *Harvard Business Review*. <https://hbr.org/2017/05/whats-your-data-strategy>
- Deloitte. (2018). *Digital Maturity Model Achieving digital maturity to drive growth*. <https://www2.deloitte.com/content/dam/Deloitte/global/Documents/Technology-Media-Telecommunications/deloitte-digital-maturity-model.pdf>
- El Arass, M., & Souissi, N. (2018). Data Lifecycle: From Big Data to SmartData. *2018 IEEE 5th International Congress on Information Science and Technology (CiSt)*, 80–87. <https://doi.org/10.1109/CIST.2018.8596547>
- Erevelles, S., Fukawa, N., & Swayne, L. (2016). Big Data consumer analytics and the transformation of marketing. *Journal of Business Research*, 69(2), 897–904. <https://doi.org/10.1016/J.JBUSRES.2015.07.001>
- Eroğlu, Ş., & Çakmak, T. (2018). Information as an organizational asset: assessment of a public organization's capabilities in Turkey: <https://doi.org/10.1177/0266666918811004>, 36(1), 58–77. <https://doi.org/10.1177/0266666918811004>
- European Comission. (b. d.). *Auditing of companies' financial statements* | European Commission. Pridobljeno 29. januar 2022., od https://ec.europa.eu/info/business-economy-euro/company-reporting-and-auditing/auditing-companies-financial-statements_en
- European Comission. (2021). *Building a data economy - Brochure*. <https://digital-strategy.ec.europa.eu/en/library/building-data-economy-brochure>
- European Commission. (2020a). *COM(2020) 767 final - Data Governance Act*. <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:52020PC0767&from=EN>
- European Commission. (2020b). *Data sharing in the EU – common European data spaces (new rules)*. https://ec.europa.eu/info/law/better-regulation/have-your-say/initiatives/12491>Data-sharing-in-the-EU-common-European-data-spaces-new-rules_en
- European Comission. (2020c). *Evropska strategija za podatke*. https://ec.europa.eu/info/strategy/priorities-2019-2024/europe-fit-digital-age/european-data-strategy_sl
- European Investment Bank. (2018). *Small businesses - The backbone of the EU economy*. <https://www.cib.org/attachments/mooc-regions-cities-sme-experts-transcript-en.pdf>
- Faroukhi, A. Z., El Alaoui, I., Gahi, Y., & Amine, A. (2020). Big data monetization throughout Big Data Value Chain: a comprehensive review. *Journal of Big Data*, 7(1), 1–22. <https://doi.org/10.1186/s40537-019-0281-5>
- Farzaneh, M., Mozaffari, F., Ameli, S. P., Karami, M., Mohamadian, A., & Arianyan, E. (2019). Designing an Organizational Readiness Framework for Big Data Adoption. V M. Farzaneh, F. Mozaffari, S. P. Ameli, M. Karami, A. Mohamadian, & E. Arianyan (Ur.), *9th International Symposium on Telecommunication: With Emphasis on Information and Communication Technology, IST 2018* (str. 387–391). IEEE. <https://doi.org/10.1109/ISTEL.2018.8661073>
- GAIA-X. (2021). *GAIA-X - Home*. Pridobljeno 2. september 2021., od <https://www.data-infrastructure.eu/GAIAX/Navigation/EN/Home/home.html>
- Gandhi, S., Thota, B., Kuchembuck, R., & Swartz, J. (2018). Demystifying data monetization. *MIT Sloan Management Review*. <https://sloanreview.mit.edu/article/demystifying-data-monetization/>
- Gartner. (2018). *Gartner Survey Shows Organizations Are Slow to Advance in Data and Analytics*. <https://www.gartner.com/en/newsroom/press-releases/2018-02-05-gartner-survey-shows-organizations-are-slow-to-advance-in-data-and-analytics>
- Ghosh, P. (Guha). (2020). *Data Architecture and Artificial Intelligence: How Do They Work Together?* <https://www.dataversity.net/data-architecture-artificial-intelligence-work-together/#>
- Gökalp, M. O., Gökalp, E., Gökalp, S., & Koçyiğit, A. (2021). The development of data analytics maturity assessment framework: DAMAF. *Journal of Software: Evolution and Process*.

- <https://doi.org/10.1002/smr.2415>
- Gourinchas, P.-O., Kalemli-Özcan, Şebnem, Penciakova, V., & Sander, N. (2020). COVID-19 AND SME FAILURES. https://www.ecb.europa.eu/pub/conferences/shared/pdf/20211011_mon_pol_conf/Kalemli-OzcanSME_Failures.pdf
- Grossman, R. L. (2018). A framework for evaluating the analytic maturity of an organization. *International Journal of Information Management*, 38(1), 45–51. <https://doi.org/10.1016/j.ijinfomgt.2017.08.005>
- Guangming, C., Yao, L., Zhiwei, G., & Xiaoyin, L. (2017). Cloud Data Governance Maturity Model. *8th IEEE International Conference on Software Engineering and Service Science (ICSESS)*, 517–520. <https://doi.org/10.1109/ICSESS.2017.8342968>
- Günther, L. C., Colangelo, E., Wiendahl, H.-H., & Bauer, C. (2019). Data quality assessment for improved decision-making: a methodology for small and medium-sized enterprises. *Procedia Manufacturing*, 29, 583–591. <https://doi.org/https://doi.org/10.1016/j.promfg.2019.02.114>
- Gurkan Inan, G., & Bititci, U. S. (2015). Understanding organizational capabilities and dynamic capabilities in the context of micro enterprises: a research agenda peer-review under responsibility of 4 th International Conference on Leadership, Technology, Innovation and Business Management. *Procedia-Social and Behavioral Sciences*, 210, 310–319. <https://doi.org/10.1016/j.sbspro.2015.11.371>
- Hammouchi, H., Cherqi, O., Mezzouri, G., Ghogho, M., & El Koutbi, M. (2019). Digging Deeper into Data Breaches: An Exploratory Data Analysis of Hacking Breaches Over Time. *Procedia Computer Science*, 151, 1004–1009. <https://doi.org/10.1016/J.PROCS.2019.04.141>
- Hanafizadeh, P., & Harati Nik, M. R. (2020). Configuration of Data Monetization: A Review of Literature with Thematic Analysis. *Global Journal of Flexible Systems Management*, 21(1), 17–34. <https://doi.org/10.1007/s40171-019-00228-3>
- Haug, A., Zachariassen, F., & van Liempd, D. (2011). The costs of poor data quality. *Journal of Industrial Engineering and Management*, 4(2), 168–193. <https://doi.org/10.3926/JIEM.2011.V4N2.P168-193>
- Heredia-Vizcaíno, D., & Nieto, W. (2019). A Governing Framework for Data-Driven Small Organizations in Colombia. *Advances in Intelligent Systems and Computing*, 930, 622–629. https://doi.org/10.1007/978-3-030-16181-1_59
- Hornick, M. (2020). *A Data Science Maturity Model for Enterprise Assessment*. <https://www.oracle.com/a/devo/docs/data-science-maturity-model.pdf>
- Hossain, A., Akter, S., & Yanamandram, V. (2020). Revisiting customer analytics capability for data-driven retailing. *Journal of Retailing and Consumer Services*, 56, 1–13. <https://doi.org/10.1016/j.jretconser.2020.102187>
- <https://dihslovenia.si/>. (2020). *Digitalno inovacijsko stičišče Slovenije - Digitalno inovacijsko stičišče Slovenije*. <https://dihslovenia.si/>
- Humphrey, W. S. (1988). Characterizing the Software Process: A Maturity Framework. *IEEE Software*, 5(2), 73–79. <https://doi.org/10.1109/52.2014>
- IBM. (2007). *IBM data governance maturity model*. <https://www.lightsondata.com/data-governance-maturity-models-ibm/>
- Igartua, J. I., Retegi, J., & Ganzarain, J. (2018). IM2, a Maturity Model for Innovation in SMEs. *Dirección y Organización*, 64, 42–49. <https://www.revistadyo.es/index.php/dyo/article/viewFile/521/542>
- Jukić, N., & Sharma, A. (2015). Augmenting Data Warehouses with Big Data. *Information Systems Management*, 32(3), 200–209. <https://doi.org/10.1080/10580530.2015.1044338>
- Kaidalova, J., Sandkuhl, K., & Seigerroth, U. (2018). How Digital Transformation affects Enterprise Architecture Management-a case study. *International Journal of Information Systems and Project Management*, 6(3), 5–18. <https://doi.org/10.12821/ijispdm060301>
- Kilkenny, M. F., & Robinson, K. M. (2018). Data quality: “Garbage in – garbage out”. *Health Information Management Journal*, 47(3), 103–105. <https://doi.org/10.1177/1833358318774357>

- Kiron, D., Ferguson, R. B., & Kirk Prentice, P. (2013). From Value to Vision: Reimagining the Possible with Data Analytics. *MIT Sloan Management Review*, 54(3). <https://sloanreview.mit.edu/projects/from-value-to-vision-reimagining-the-possible-with-data-analytics/>
- Kljajic Borštnar, M. (2022). *Modeliranje odločitvenega znanja*.
- Kljajic Borštnar, M., Ilijas, T., & Pucihar, A. (2015). ASSESSMENT OF CLOUD HIGH PERFORMANCE COMPUTING. V L. Zadnik Stirn (Ur.), *13th International Symposium on Operational Research in Slovenia* (str. 23–28). Slovenian Society Informatika, Section for Operational Research.
- Kljajic Borštnar, M., & Pucihar, A. (2021). Multi-Attribute Assessment of Digital Maturity of SMEs. *V Electronics* (Let. 10, Številka 8). <https://doi.org/10.3390/electronics10080885>
- Kremser, W., & Brunauer, R. (2019). *Do we have a Data Culture? BT - Data Science – Analytics and Applications* (P. Haber, T. Lampoltshammer, & M. Mayr (Ur.); str. 83–87). Springer Fachmedien Wiesbaden.
- Król, K., & Zdonek, D. (2020). Analytics maturity models: An overview. *Information*, 11(3), 1–19. <https://doi.org/10.3390/info11030142>
- Lehrer, C., Wieneke, A., vom Brocke, J., Jung, R., & Seidel, S. (2018). How Big Data Analytics Enables Service Innovation: Materiality, Affordance, and the Individualization of Service. *Journal of Management Information Systems*, 35(2), 424–460. <https://doi.org/10.1080/07421222.2018.1451953>
- Limpeetcharoenchot, S., Cooharojananone, N., Chavarnakul, T., Tuaycharoen, N., & Atchariyachanvanich, K. (2020). Innovative Mobile Application for Measuring Big Data Maturity: Case of SMEs in Thailand. *International Journal of Interactive Mobile Technologies (IJIM)*, 14(18), 87–106. <https://doi.org/10.3991/IJIM.V14I18.16295>
- López-Cabarcos, M. Á., Göttling-Oliveira-Monteiro, S., & Vázquez-Rodríguez, P. (2015). Organizational Capabilities and Profitability: The Mediating Role of Business Strategy. *SAGE Open*, 1–13. <https://journals.sagepub.com/doi/pdf/10.1177/2158244015616852>
- Loshin, D. (2011). Data quality maturity. V J. Niles & D. Bevans (Ur.), *The Practitioner's Guide to Data Quality Improvement* (str. 44–51). Morgan Kaufman - Elsevier. https://books.google.si/books?hl=en&lr=&id=B3zd4GCAWeYC&oi=fnd&pg=PR3&dq=iinfo:qMsybD7zSZUJ:scholar.google.com&ots=0SVyX2ZfGX&sig=Hux9Ymbl0emIu8MjTCqmY3CiheU&redir_esc=y#v=onepage&q&f=false
- Marchildon, P., Bourdeau, S., Hadaya, P., & Labissière, A. (2018). *Data governance maturity assessment tool: A design science approach*. <https://www.cairn.info/revue-projectique-2018-2-page-155.htm>
- Mikalef, P., Boura, M., Lekakos, G., & Krogstie, J. (2019). Big data analytics and firm performance: Findings from a mixed-method approach. *Journal of Business Research*, 98, 261–276. <https://doi.org/10.1016/j.jbusres.2019.01.044>
- Mintzberg, H. (1990). The Manager's Job: Folklore and Fact. *Harvard Business Review*. <https://hbr.org/1990/03/the-managers-job-folklore-and-fact>
- Moonen, N., Baijens, J., Ebrahim, M., & Helms, R. (2019). *Small Business, Big Data: An Assessment Tool for (Big) Data Analytics Capabilities in SMEs*. <https://remhelms.files.wordpress.com/2019/05/small-business-big-data-an-assessment-framework-for-big-data-analytics-capabilities-in-smes.pdf>
- Mouhib, S., Anoun, H., Ridouani, M., & Hassouni, L. (2020). Towards a Global Big Data Maturity Model. *4th International Conference on Intelligent Computing in Data Sciences, ICDS 2020*, 1–5. <https://doi.org/10.1109/ICDS50568.2020.9268720>
- Nasrollahi, M., & Ramezani, J. (2020). A Model to Evaluate the Organizational Readiness for Big Data Adoption. *INTERNATIONAL JOURNAL OF COMPUTERS COMMUNICATIONS & CONTROL*, 15(3), 1–11. <http://www.univagora.ro/jour/index.php/ijccc/article/view/3874/1402>
- Nasrollahi, Mahdi, Ramezani, J., & Sadraei, M. (2021). The Impact of Big Data Adoption on SMEs' Performance. *Big Data and Cognitive Computing*, 5(4). <https://doi.org/10.3390/bdcc5040068>

- OECD. (2019). VECTORS OF DIGITAL TRANSFORMATION (Številka 273). <https://www.oecd-ilibrary.org/docserver/5ade2bba-en.pdf?expires=1642513384&id=id&accname=guest&checksum=80A3420ACB614731418295B628560F9E>
- OECD. (2021). The Digital Transformation of SMEs. <https://doi.org/10.1787/bdb9256a-en>
- Olszak, C. M., & Mach-Król, M. (2018). A Conceptual Framework for Assessing an Organization's Readiness to Adopt Big Data. *Sustainability*, 10(10), 3734. <https://doi.org/10.3390/SU10103734>
- Parnell, J. A. (2013). Uncertainty, Generic Strategy, Strategic Clarity, and Performance of Retail SMEs in Peru, Argentina, and the United States. *Journal of Small Business Management*, 51(2), 215–234. <https://doi.org/10.1111/JSBM.12010>
- Parra, X., Tort-Martorell, X., Ruiz-Viñals, C., & Álvarez-Gómez, F. (2019). A Maturity Model for the Information-Driven SME. *Journal of Industrial Engineering and Management (JIEM)*, 12(1), 154–175. <https://doi.org/10.3926/jiem.2780>
- Peña, A., Bonet, I., Lochmuller, C., Tabares, M. S., Piedrahita, C. C., Sánchez, C. C., Giraldo Marín, L. M., Góngora, M., & Chiclana, F. (2018). A fuzzy ELECTRE structure methodology to assess big data maturity in healthcare SMEs. *Soft Computing*, 23(20), 10537–10550. <https://doi.org/10.1007/S00500-018-3625-8>
- Peng, G. (2018). The state of assessing data stewardship maturity – An overview. *Data Science Journal*, 17(0). <https://doi.org/10.5334/DSJ-2018-007/METRICS/>
- Pillay, K., & van der Merwe, A. (2021). Big Data Driven Decision Making Guidelines for South African Banking Institutions. *2021 International Conference on Artificial Intelligence, Big Data, Computing and Data Communication Systems (icABCD)*, 1–6. <https://doi.org/10.1109/icABCD51485.2021.9519373>
- Porter, M. E. (1980). *Competitive strategy: Techniques for analyzing industries and competitors*. [http://www.mim.ac.mw/books/Michael E. Porter - Competitive Strategy.pdf](http://www.mim.ac.mw/books/Michael%20E.%20Porter%20-%20Competitive%20Strategy.pdf)
- Power, D. J. (2008). Understanding Data-Driven Decision Support Systems. *Information Systems Management*, 25(2), 149–154. <https://doi.org/10.1080/10580530801941124>
- Power, D. J., & Sharda, R. (2007). Model-driven decision support systems: Concepts and research directions. *Decision Support Systems*, 43(3), 1044–1061. <https://doi.org/https://doi.org/10.1016/j.dss.2005.05.030>
- Price, R., & Shanks, G. (2008). *Data Quality and Decision Making BT - Handbook on Decision Support Systems 1: Basic Themes* (F. Burstein & C. W. Holsapple (Ur.); str. 65–82). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-48713-5_4
- Provost, F., & Fawcett, T. (2013). Data Science and its Relationship to Big Data and Data-Driven Decision Making. *Big Data*, 1(1), 51–59. <https://doi.org/10.1089/big.2013.1508>
- Pugna, I. B., Duțescu, A., & Stanila, O. G. (2019). Corporate Attitudes towards Big Data and Its Impact on Performance Management: A Qualitative Study. *Sustainability*, 11(3). <https://doi.org/10.3390/SU11030684>
- Qin, S. J. (2014). Process data analytics in the era of big data. *AICHE Journal*. <https://doi.org/10.1002/aic.14523>
- Ramasamy, A., & Chowdhury, S. (2020). Big Data Quality Dimensions: A Systematic Literature Review. *Journal of Information Systems and Technology Management*. <https://doi.org/10.4301/S1807-1775202017003>
- Rejikumar, G., Aswathy Asokan, A., & Sreedharan, V. R. (2020). Impact of data-driven decision-making in Lean Six Sigma: an empirical analysis. *Total Quality Management and Business Excellence*, 31(3–4), 279–296. <https://doi.org/10.1080/14783363.2018.1426452>
- Rogers, K. (2020). Creating a Culture of Data-Driven Decision-Making [ProQuest LLC]. V *ProQuest Dissertations and Theses*. <https://search-proquest-com.ezproxy.lib.ukm.si/pqdglobal/docview/2461428896/fulltextPDF/337FD22C0C5B433BPQ/?accountid=28931#>
- Ryu, K.-S., Park, J.-S., & Park, J.-H. (2006). A Data Quality Management Maturity Model. *ETRI Journal*,

- 28(2), 191–204. <https://doi.org/10.4218/ETRIJ.06.0105.0026>
- Saputra, D. A., Handika, D., & Ruldeviyani, Y. (2018). Data Governance Maturity Model (DGM2) Assessment in Organization Transformation of Digital Telecommunication Company: Case Study of PT Telekomunikasi Indonesia. *2018 International Conference on Advanced Computer Science and Information Systems (ICACSIS)*, 325–330. <https://doi.org/10.1109/ICACSIS.2018.8618255>
- Schumacher, A., Erol, S., & Sihin, W. (2016). A Maturity Model for Assessing Industry 4.0 Readiness and Maturity of Manufacturing Enterprises. *Procedia CIRP*, 52, 161 – 166. <https://doi.org/10.1016/j.procir.2016.07.040>
- Sen, A., Ramamurthy, K., & Sinha, A. P. (2012). A Model of Data Warehousing Process Maturity. *IEEE Transactions on Software Engineering*, 38(2), 336–353. <https://doi.org/10.1109/TSE.2011.2>
- Shah, S., Horne, A., & Capellá, J. (2012). Good Data Won't Guarantee Good Decisions. *Harvard Business Review*, 90(4), 23–26. <https://hbr.org/2012/04/good-data-wont-guarantee-good-decisions>
- Shah, S. I. H., Peristeras, V., & Magnialis, I. (2021). DaLiF: a data lifecycle framework for data-driven governments. *Journal of Big Data*, 8(89), 1–44. <https://doi.org/10.1186/S40537-021-00481-3>
- Sherman, R. (2015). Data Architecture. V *Business Intelligence Guidebook* (str. 107–142). Morgan Kaufmann. <https://doi.org/10.1016/b978-0-12-411461-6.00006-x>
- Spiekermann, M. (2019). Data Marketplaces: Trends and Monetisation of Data Goods. *Intereconomics*, 54(4), 208–216. <https://doi.org/10.1007/s10272-019-0826-z>
- Spruit, M., & Pietzka, K. (2015a). MD3M: The master data management maturity model. *Computers in Human Behavior*, 51, 1068–1076. <https://doi.org/10.1016/j.chb.2014.09.030>
- Spruit, M., & Pietzka, K. (2015b). MD3M: The master data management maturity model. *Computers in Human Behavior*, 51, 1068–1076. <https://doi.org/10.1016/j.chb.2014.09.030>
- Sternkopf, H., & Mueller, R. M. (2018). Doing Good with Data: Development of a Maturity Model for Data Literacy in Non-governmental Organizations. *Proceedings of the 51st Hawaii International Conference on System Sciences*, 5045–5054. <https://core.ac.uk/download/pdf/143481465.pdf>
- Stobierski, T. (2019, avgust 26). *The Advantages of Data-Driven Decision-Making*. <https://online.hbs.edu/blog/post/data-driven-decision-making>
- SURS. (2020). *Analiza masovnih podatkov (big data) v podjetjih v prejšnjem letu, po velikosti podjetij glede na število zaposlenih oseb, Slovenija, 2020.* <https://pxweb.stat.si/SiStatData/pxweb/sl/Data/-/2977603S.px/table/tableViewLayout2/>
- Šverko, P. (2009). VARNOST PODATKOV KOT DEL NJIHOVEGA MANAGEMENTA. *Zbornik 6. študentske konference Fakultete za management Koper*, 923–930. https://www.fmkp.si/zalozba/ISBN/978-961-266-033-8/prispevki/Sverko_Peter.pdf
- Tan, Z., Nagar, U. T., He, X., Nanda, P., Liu, R. P., Wang, S., & Hu, J. (2014). Enhancing big data security with collaborative intrusion detection. *IEEE Cloud Computing*, 1(3), 27–33. <https://doi.org/10.1109/MCC.2014.53>
- Teichert, R. (2019). DIGITAL TRANSFORMATION MATURITY: A SYSTEMATIC REVIEW OF LITERATURE. *ACTA UNIVERSITATIS AGRICULTURAE ET SILVICULTURAE MENDELIANAЕ BRUNENSIS*, 67(6), 1673–1687. <https://acta.mendelu.cz/pdfs/acu/2019/06/27.pdf>
- TOGAF. (2018). TOGAF® Standard, Version 9.2 - Core Concepts. <https://pubs.opengroup.org/architecture/togaf9-doc/arch/chap02.html>
- Turner, S., & Endres, A. (2017). Strategies for Enhancing Small-Business Owners' Success Rates. *International Journal of Applied Management and Technology*, 16(1), 34–49. <https://doi.org/10.5590/IJAMT.2017.16.1.03>
- Ulrich, W. (2010). Introduction to Architecture-Driven Modernization. V *Information Systems Transformation* (str. 30). Morgan Kaufmann. <https://books.google.si/books?id=hDzIedYPG7AC&pg=PA30&lpg=PA30&dq=Data+Architecture+Derivation+and+Transformation+Data+architecture+is+a+very+important+aspect+of+any+transformation+project+because+aging+data+architectures+are+redundant,+intractable,+and+>

- Valdez de Leon, O. (2016). A Digital Maturity Model for Telecommunications Service Providers. *Technology Innovation Management Review*, 6(8), 19–32. <https://doi.org/10.22215/TIMREVIEW/1008>
- Verhoef, P. C., Broekhuizen, T., Bart, Y., Bhattacharya, A., Dong, J. Q., Fabian, N., & Haenlein, M. (2019). Digital transformation: A multidisciplinary reflection and research agenda. *Journal of Business Research*, 122, 889–901. <https://doi.org/10.1016/j.jbusres.2019.09.022>
- Waller, D. (2020). 10 Steps to Creating a Data-Driven Culture. *Harrard Business Review*. <https://hbr.org/2020/02/10-steps-to-creating-a-data-driven-culture>
- Wang, R. Y., & Strong, D. M. (1996). Beyond Accuracy: What Data Quality Means to Data Consumers. *Journal of Management Information Systems*, 12(4), 5–33. http://mitiq.mit.edu/Documents/Publications/TDQMpub/14_Beyond_Accuracy.pdf
- Weritz, P., Braojos, J., & Matute, J. (2020). Exploring the Antecedents of Digital Transformation: Dynamic Capabilities and Digital Culture Aspects to Achieve Digital Maturity. *AMCIS 2020 Proceedings*, 1–10. https://www.researchgate.net/profile/Pauline-Weritz/publication/342923878_Exploring_the_Antecedents_of_Digital_Transformation_Dynamic_Capabilities_and_Digital_Culture_Aspects_to_Achieve_Digital_Maturity/links/5f0dce29a6fdcc3ed705711d/Exploring-the-Anteced
- Windt, B., Borgman, H., & Amit, C. (2019). Understanding Leadership Challenges and Responses in Data-driven Transformations. *Proceedings of the 52nd Hawaii International Conference on System Sciences*, 4987–4996. <https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1615&context=hicss-52>
- Wixom, B. H., & Ross, J. W. (2017). How to monetize your data. *MIT Sloan Management Review*. <https://sloanreview.mit.edu/article/how-to-monetize-your-data/>
- Zimmermann, V. (2016). *SMEs and digitalisation: The current position, recent developments and challenges* (Številka 138). https://www.kfw.de/PDF/Download-Center/Konzernthemen/Research/PDF-Dokumente-Fokus-Volkswirtschaft/Fokus-englische-Dateien/Fokus-2016-EN/Fokus-Nr.-138-August-2016-Digitalisierung_EN.pdf

