

# NABOR KRITERIJEV ZA OCENJEVANJE PODATKOVNE ZRELOSTI V MALIH IN SREDNJE- VELIKIH PODJETJIH

BLAŽ GAŠPERLIN, ANDREJA PUCIHAR, MIRJANA KLJAJIĆ  
BORŠTNAR

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

**Povzetek** Digitalna preobrazba se premika proti novi paradigm, podatkovno-voden digitalni preobrazbi. Z večanjem količine podatkov naraščata tudi potreba in zmožnost učinkovitega upravljanja s podatki. Mala in srednje velika podjetja (MSP) pri tem prizadevanju zaostajajo, ker jim pogosto primanjkuje virov (finančnih, človeških, časovnih, znanj) za prehod iz podatkovno nezrelega v podatkovno zrelo podjetje. Kot odgovor na to težavo so bili predlagani in razviti številni modeli za ocenjevanje podatkovne zrelosti, vendar so preveč splošni, vsebujejo nepopoln nabor kriterijev za celovito oceno zrelosti upravljanja podatkov ali pa so osredotočeni na velika podjetja in zato manj primerni za MSP. V tem prispevku se osredotočamo na izbiro kriterijev za ocenjevanje podatkovne zrelosti MSP. Pri oblikovanju kriterijev smo sledili raziskovalnemu pristopu načrtovanja in razvoja (ang. design science research) in korakom DEX metodologije. Izbrani kriteriji bodo podlaga za razvoj večkriterijskega modela za ocenjevanje podatkovne zrelosti MSP.

**Ključne besede:**  
digitalna  
preobrazba,  
ocenjevanje  
podatkovne  
zrelosti,  
kriteriji  
podatkovne  
zrelosti,  
DEX,  
MSP

# A SET OF DATA MATURITY ASSESSMENT CRITERIA FOR SMALL AND MEDIUM-SIZED ENTERPRISES

BLAŽ GAŠPERLIN, ANDREJA PUCIHAŘ, MIRJANA KLJAJIĆ  
BORŠTNAR

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

**Abstract** Digital transformation is moving toward a new paradigm, data-driven digital transformation. As the amount of data increases, so does the need and capability to manage data efficiently. Small and medium-sized enterprises (SMEs) lag behind in this effort because they often lack the resources (financial, human, time, knowledge) to move from a data-immature to a data-mature enterprise. In response to this problem, a number of data maturity assessment models have been proposed and developed, but they are too general, contain an incomplete set of criteria to comprehensively assess data maturity, or are focused on large enterprises and therefore less suitable for SMEs. In this paper, we focus on selecting criteria for assessing SMEs' data maturity. In formulating the criteria, we followed a design science research approach and the steps of a DEX methodology. The selected criteria will serve as the basis for the development of a multi-criteria model for assessing the data maturity of SMEs.

**Keywords:**  
Digital transformation,  
data maturity assessment,  
data maturity criteria,  
DEX,  
SMEs

## 1 Uvod

Razvoj in napredek digitalnih tehnologij v zadnjem desetletju je spodbudil preobrazbo organizacij, da so postale bolj digitalne v svojem načinu poslovanja, omogočil razvoj novih digitalnih izdelkov in storitev ter ustvarjanje novih poslovnih modelov (Dąbrowska idr., 2022). Te spremembe so posledica hitrih sprememb poslovnega okolja, ki jih vodi proces digitalne preobrazbe (Pora idr., 2022). Uporaba digitalnih tehnologij se odraža tudi v visokem porastu in dostopnosti podatkov, ki postajajo glavni vir digitalnega razvoja organizacij (Hanelt idr., 2021; Vial, 2019). V tem kontekstu se digitalna preobrazba pomika proti novi paradigm, imenovani podatkovno vodena digitalna preobrazba. Podatkovno-vodena preobrazba je proces, pri katerem organizacija preoblikuje svojo infrastrukturo, strategije, način poslovanja, tehnologije ali organizacijsko kulturo, da olajša in spodbudi vedenje pri odločanju, ki temelji na podatkih (Areerakulkhan & Pongpech, 2021; Hagen & Hess, 2020).

Za podatkovno-vodeno organizacijo je potreben celovit pregled nad podatki, visoko razvite analitične veščine in tehnike za raziskovanje, ekstrakcijo in razumevanje vzorcev iz podatkov (Santos idr., 2015), da lahko to pretvorimo v uporabno znanje, na podatke pa gledati kot na strateški vir za ustvarjanje novih izdelkov, storitev, poslovnih modelov, povečevanje vrednosti in sprejemanje odločitev (Charnley idr., 2019; Haucap, 2019). Sprejemanje odločitev, ki temeljijo na podatkih, postaja nuja (Carnicero idr., 2021) kot odgovor na poplavo podatkov in informacij, ki so danes na voljo. V primerjavi z velikimi podjetji, so mala in srednje velika podjetja (MSP) običajno manj digitalno zrela in imajo svoje podatke slabše organizirane in slabo upravljane (Gudfinnsson & Strand, 2017; Mohamed & Weber, 2020). MSP so pogosto omejena s finančnimi in človeškimi viri ter znanjem, kako napredovati v trenutnem stanju podatkovne zrelosti (Nkwabi idr., 2019; Virkkala idr., 2020). Za celovito oceno podatkovne zrelosti moramo upoštevati več kriterijev: kulturo (Karaboga idr., 2019), strategijo (Gür idr., 2021), kakovost podatkov (Heinrich, 2017), varnost podatkov (Sekarhati idr., 2019), življenski cikel podatkov (Sinaeepourfard idr., 2016), tehnologijo in orodja za podatkovno analitiko (Farah, 2017) in druge.

V tem prispevku se osredotočamo na opredelitev kriterijev, pomembnih za ocenjevanje podatkovne zrelosti MSP. Kljub številnim razpoložljivim modelom

podatkovne zrelosti, v literaturi nismo zasledili modela, ki bi s predlaganimi kriteriji zagotovil celovito oceno podatkovne zrelosti MSP in bil prilagojen potrebam in karakteristikam MSP. Kriteriji, ki jih trenutni modeli predlagajo, so bodisi preveč kompleksni, bodisi nepopolni pri predlaganem naboru kriterijev in zato neprimerni za MSP. Opredeljen nabor kriterijev bo podlaga za razvoj preliminarnega modela ocenjevanja podatkovne zrelosti, ki temelji na metodologiji DEX. V prispevku začnemo s pregledom literature obstoječih modelov podatkovne zrelosti in njihovih kriterijev ter nadaljujemo z raziskovalno metodologijo. Nato predstavimo izbrane kriterije za oceno podatkovne zrelosti MSP in zaključimo s predlogom za nadaljnjo raziskavo.

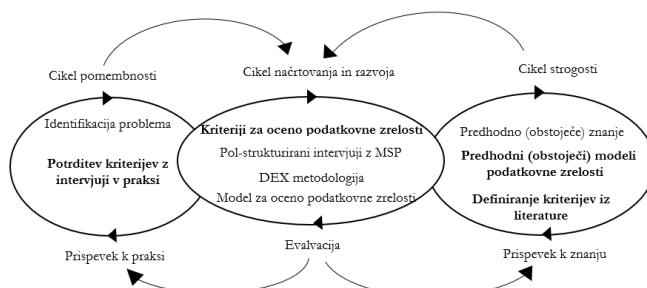
## 2 Teoretična izhodišča

Literatura o podatkovni zrelosti narašča, vendar je še vedno v veliki meri osredotočena na preveč splošne predloge modelov (Baars idr., 2016), ki bi MSP pomagali oceniti podatkovno zrelost celovito. Prejšnji modeli podatkovne zrelosti, ki so jih razvile svetovalne organizacije (IBM, Gartner, TDWI, Deloitte, Accenture, CMMI Institute) so po številu kriterijev preobsežni in v svoji strukturi preveč statični, kar pomeni, da vsi predlagani kriteriji zaradi prej omenjenih omejitev za MSP niso primerni. V preteklosti so se avtorji na področju podatkovne zrelosti večinoma osredotočali na poslovno inteligenco (Boonsirithomachai idr., 2016; Chen & Nath, 2018; Llave idr., 2018) in industrijo 4.0 (Chonsawat & Sopadang, 2019; Colli idr., 2018; Mittal idr., 2018). Raziskave in osredotočenost pri modelih podatkovne zrelosti so se nato premaknile na oceno zrelosti podatkovne analitike (Karaboga idr., 2019; Maroufkhani idr., 2020; Mohamed & Weber, 2020). Najnovejši modeli za oceno podatkovne zrelosti se začenjajo osredotočati na oceno zrelosti umetne inteligence (Alsheiabni idr., 2019; Sadiq idr., 2021), masovne podatke (Noonpakdee idr., 2018; Olszak & Mach-Król, 2018) in področje odločanja (Alhawamdeh & Alsmairat, 2019; Brous idr., 2016). (Peña idr., 2018) so predlagali večkriterijski model za ocenjevanje zrelosti upravljanja velikih podatkov za organizacije, ki delujejo v zdravstvenem sektorju. Čeprav so se avtorji omejili na MSP, predlagani model temelji na metodi mehke logike ELECTRE kot pristopu ocenjevanja, ki je za MSP težje razumljiv, saj temelji na matematičnih operacijah in izrazih.

Drugi (Limpeeticharoenchot idr., 2022) so se osredotočili na področje analitike velikih podatkov in predlagali model zrelosti, prek katerega lahko MSP ocenijo, v kateri fazi zrelosti so pri uporabi velikih podatkov. Ocena zrelosti velikih podatkov je temeljila na štirih zmožnostih: 1) organizacijski dejavniki in dejavniki odnosa, 2) informacijska tehnologija, 3) tehnologija vezana na uporabo analitičnih orodij in 4) pripravljenost ljudi. Omejitev predlaganega modela je v njegovem ocenjevalnem pristopu, saj MSP-jem podaja oceno v obliki številčne ocene (od 1 do 5), vendar ne predлага posebej, katere korake naj MSP sprejme za izboljšanje zrelosti velikih podatkov in predstavljene zmogljivosti. Modelu manjkajo tudi nekateri kriteriji, ki so potrebni za celovito oceno podatkovne zrelosti, kot je na primer uporaba podatkov za podporo odločanju (Nijzink, 2020), varnost podatkov (Sekarhati idr., 2019), strategija (Gür idr., 2021), idr.

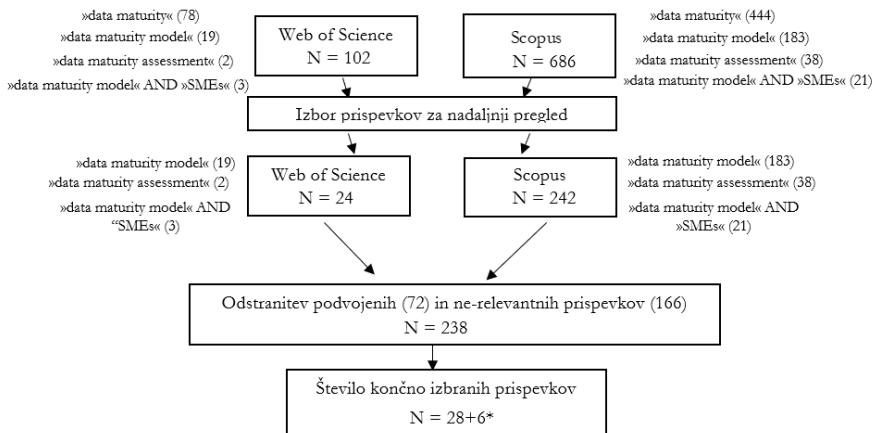
### 3 Metodologija

Kot raziskovalni pristop smo uporabili pristop načrtovanja in razvoja (ang. Design Science Research - DSR) (Hevner idr., 2004) (Slika 1). DSR opisujejo trije glavni raziskovalni cikli (cikel strogosti, cikel pomembnosti ter cikel načrtovanja in razvoja) (Hevner, 2007). Rezultat predstavlja razvit artefakt (tj. konstrukt, model, metoda), v našem primeru bo to večkriterijski model za oceno podatkovne zrelosti MSP, kjer sledimo metodologiji modeliranja večkriterijskega odločitvenega znanja kvalitativne metode DEX (Bohanec idr., 2013). V tem prispevku se osredotočamo na prvi korak v metodologiji DEX, to je identifikacijo relevantnih kriterijev, s katerimi bo moč oceniti podatkovno zrelost organizacije. Na podlagi identifikacije problema in pregleda literature smo identificirali trenutno obstoječe modele podatkovne zrelosti in opredelili ustrezne kriterije (cikel strogosti).



**Slika 1: Raziskovalni pristop metodologije DSR – prirejeno po (Hevner, 2007)**

Iskanje smo izvedli v bazah podatkov Web of Science (Wos) in Scopus. Uporabili smo iskalne poizvedbe ‐data maturity model”, ‐data maturity assessment” in ‐data maturity model” AND ‐SMEs” in izvedli iskanje po vseh iskalnih poljih. Število najdenih prispevkov po specifičnem iskalnem nizu oziroma ključni besedi je razvidno s slike 2. V prvotnem naboru prispevkov smo pregledali naslove in povzetke in izločili vse prispevke, ki se ne nanašajo na podatkovno zrelost. Tako smo izmed 102 prispevkov v bazi WoS za nadaljnji pregled izbrali 24 prispevkov, v bazi Scopus pa 242 izmed 444 prispevkov. Izmed prispevkov, ki smo jih uvrstili v nadaljnji pregled, smo prispevke, katerih celotna vsebina ni bila na voljo (1 prispevek), niso bili napisani v angleščini (3 prispevki), so bili podvojeni (takšnih je bilo 72 prispevkov) ali niso imeli povezave z modeli za oceno zrelosti podatkov (166 prispevkov), smo prav tako izločili iz nadaljnje analize. Nekateri prispevki niso bili dostopni, zato smo jih poskušali poiskati preko drugih repozitorijev, kot je ResearchGate. Pregledali smo tudi modele, ki so jih razvile raziskovalne ustanove ali organizacije (IBM, Gartner, TDWI, Deloitte, Accenture, CMMI Institute). Na koncu smo identificirali 28 prispevkov, relevantnih za našo raziskavo, skupaj s šestimi omenjenimi modeli raziskovalnih ustanov. Slika 2 prikazuje postopek pregleda z bazami podatkov in iskalnimi poizvedbami za vsako bazo podatkov.



**Slika 2: Proses pregleda literature**

Po pregledu literature smo začeli s postopkom izbire kriterijev, ki smo jih identificirali iz literature. Pri tem smo sledili korakom metodologije DEX (Bohanec idr., 2013), ki je del večkriterijskih odločitvenih metod. Na podlagi pregleda modelov in njihovih kriterijev smo definirali neurejen seznam 108 kriterijev. Zaradi velikega števila kriterijev je prikazan le del kriterijev, ki smo jih izbrali kot relevantne za nadaljnji izbor (Slika 3).

Vodenje	Znanja	Upravljanje premoženja
Investiranje	Miselnost	Ljudje
Strategija	Tehnike	Proces
Kultura	Aplikacije	Zbiranje podatkov ali analitična orodja
Vrednost	Načini dostave	Regulativna in etika
Razvoj	Politike	Podpora uporabnikom
Tehnologije	Struktura	Formalizacija
Arhitektura	Skladnost	Meta podatki
Integracija	Skrbništvo	Matični podatki
Obseg	Varnost in zasebnost	Zavedanje
Raznolikost, obseg, hitrost	Vloge	Kadri
Obdelava	Sodelovanje	Strategija kakovosti podatkov
Hramba	Metodologija	Tipi podatkov
Kakovost	Zavedanje o podatkih	Zunanje izvajanje
Dostop	Dostop do podatkov	Podpora vodstva
Izobraževanje	Elastičnost	Podatkovno inoviranje

Slika 3: Neurejen seznam kriterijev

V naslednjem koraku (Slika 4) smo identificirane kriterije združili po podobnosti in odstranili podvojene kriterije.

1 Vodenje	5 Vrednost	25 Skrbništvo
16 Izobraževanje	9 Zdrževanje (integracija)	26 Varnost in zasebnost
17 Znanja	13 Hramba (podatkov)	97 Zaščita podatkov
27 Vloge	14 Kakovost (podatkov)	10 Obseg (okvir)
28 Sodelovanje	62 Zdrževanje (integracija) podatkov	19 Tehnike podatkovne analitike
44 Ljudje	4 Kultura	20 Uporaba podatkovne analitike
78 ...Spôsobnosti	18 Miselnost	21 Način posredovanja analiziranih podatkov
104 Znanja	30 Zavedanje o podatkih	36 Proces
105 ...Zmožnost	35 Ljudje	37 Orodja za zbiranje podatkov ali analitiko
106 ...Skills	43 Zavedanje	64 Merjenje in analiza
107 ...Izobraževanja	6 Razvoj infrastrukture	85 Podatkovna analitika
108 ...Dostop do znanja in ekspertise	7 Tehnologije	86 ...Tip podatkovne analitike
2 Investiranje	32 Razširljivost in prilagodljivost orodij za uporabo	87 ...Tehnika analiziranja podatkov
3 Strategija	61 Platfoma za upravljanje podatkov	88 ...Povezovanje analiziranih podatkov
29 Metodologija	98 Orodja	89 ...Predstavitev analiziranih podatkov
47 Poslovni primer	99 ...Hramba	91 ...Namen zbiranja in analiziranja podatkov
48 Programske investicije	100 ...Vrsta orodja	
77 ...Načrti	101 ...Kakovost orodij	
79 ...Investiranje	102 ...Deljenje podatkov	
111 Zunanje izvajanje		

Slika 4: Skupine relevantnih kriterijev

Dobili smo preliminarni seznam kriterijev (z izločenimi podvojenimi kriteriji), kjer smo vsak kriterij umestili v posamezno skupino zmogljivosti: organizacijske zmogljivosti, zmogljivosti upravljanja s podatki ali tehnološke zmogljivosti (Slika 5). S tem smo želeli združiti kriterije glede na pomen posameznega kriterija in postaviti urejeno in pregledno strukturo kriterijev, za katere menimo, da so primerni za MSP.



Slika 5: Preliminarni seznam kriterijev

#### 4 Kriteriji za ocenjevanje podatkovne zrelosti za mala in srednje velika podjetja

V tem poglavju predstavljamo izbrane kriterije za oceno podatkovne zrelosti MSP. Predstavljeni kriteriji bodo podlaga za razvoj modela za ocenjevanje podatkovne zrelosti MSP. Avtorji (Moonen idr., 2019) nakazujejo, da je podatkovna zrelost organizacije povezana tudi z razvojem organizacijskih in tehnoloških zmogljivosti in z razvojem zmogljivosti upravljanja s podatki. Zato smo na podlagi (Moonen idr., 2019) izbrane kriterije razvrstili v tri skupine (organizacijske zmogljivosti, zmogljivosti upravljanja s podatki in tehnološke zmogljivosti). Organizacijske zmogljivosti se nanašajo na sposobnost podjetja, da uporabi svoje vire, opredmetene (stroji, zemljišča, zgradbe) ali neopredmetene (človeški viri, spremnosti, kultura) za izvedbo naloge ali dejavnosti za izboljšanje uspešnosti poslovanja (Akaegbu & Usoro, 2017). Zmogljivosti upravljanja s podatki so povezane s sposobnostjo usklajevanja informacijskih virov in njihove produktivne uporabe (Brinkhues idr., 2014). Tehnološke zmogljivosti se nanašajo na zmožnost organizacije za uvajanje, razvoj in uporabo tehnoloških virov ter njihovo integracijo z drugimi dopolnilnimi

viri za zagotavljanje različnih izdelkov in storitev (Omar idr., 2012). V tabelah 1 do 3 predstavljamo kriterije po posameznih skupinah opisanih zmogljivosti.

**Tabela 1: Kriteriji, povezani z organizacijskimi sposobnostmi**

Kriterij	Opis kriterija	Avtor(ji)
Vodenje	Nanaša se na slog vodenja (avtoritativen, demokratičen, inovativen)	(Halper, 2020; Peña idr., 2018)
Izobraževanje (Usposabljanje)	Organizacija usposabljanja na področju upravljanja s podatki	(Peña idr., 2018)
Znanja	Raven trenutnega znanja in večin zaposlenih na področju upravljanja s podatki	(Peña idr., 2018)
Vloge	Oseba ali oddelek, odgovoren za upravljanje podatkov	(Hornick, 2020)
Strategija	Strateška vloga podatkov - ali so podatki prepoznani kot pomemben vir v poslovni strategiji za ustvarjanje dodane vrednosti podjetja	(Gür idr., 2021)
Investiranje	Delež vlaganj letnih prihodkov v informacijsko arhitekturo in infrastrukturo	(Kljajić Borštnar & Puciher, 2021)
Zunanje izvajanje	Delež najetih zunanjih izvajalcev za upravljanje s podatki	(Moonen idr., 2019)
Miselnost	Miselnost zaposlenih pri razvoju celovitega upravljanja podatkov	(Halper, 2020)
Zavedanje	Seznanjenost zaposlenih z razpoložljivimi orodji in tehnologijami za upravljanje podatkov ter njihovimi možnostmi	(Hornick, 2020; Stanford, 2013)
Podpora vodstva	Podpora vodstva za odprto komunikacijo in sodelovanje ter spodbujanje zaposlenih k boljšemu upravljanju s svojimi podatki	(CMMI Institute, 2019; Peña idr., 2018)

**Tabela 2: Kriteriji, povezani z zmogljivostmi upravljanja s podatki**

<b>Kriterij</b>	<b>Opis kriterija</b>	<b>Avtor(ji)</b>
Obdelava podatkov	Opisuje namen obdelave podatkov in kako se ta izvaja	(Coleman idr., 2016)
Hramba podatkov	Opisuje organizacijo hrambe podatkov in zagotavljanje varnostnih kopij podatkov	(Halper, 2020; Stanford, 2013)
Dostop do podatkov	Organizacija dostopa do podatkov, ki podpirajo poslovanje	(Iqbal idr., 2019; Nijzink, 2020)
Politike upravljanja podatkov (Predpisi in etika)	Vzpostavljene in predpisane politike in smernice za upravljanje podatkov, ki jih je treba upoštevati	(Accenture, 2018; Halper, 2020)
Varnost in zasebnost	Vzpostavljenost politik varstva podatkov in varnostnih mehanizmov	(Halper, 2020; Spruit & Pietzka, 2015)
Arhiviranje	Vzpostavljenost e-arhiviranja	Dodal avtor tega prispevka
Strategija kakovosti podatkov	Vzpostavljenost strategije za zagotavljanje kakovostnih podatkov	(CMMI Institute, 2019)
Ocena kakovosti podatkov	Vzpostavljenost procesa zagotavljanja kakovosti podatkov	(CMMI Institute, 2019)
Zagotavljanje kakovosti procesa	Vzpostavljenost pregleda kakovosti podatkov in ocene kakovosti	(CMMI Institute, 2019)
Viri podatkov	Vrsta podatkovnih virov za zajem podatkov (notranji, zunanji, javni podatki)	(Nijzink, 2020)
Viri odločanja	Viri podatkov, ki se uporabljajo pri sprejemanju strateških odločitev	(Kljajić Borštnar & Pucihar, 2021; Nijzink, 2020)
Stil odločanja na podlagi podatkov	Opisuje stil sprejemanja odločitev (intuicija; delno uporaba podatkov, delno intuicija; odločitve na podlagi podatkov)	(Kljajić Borštnar & Pucihar, 2021; Parra idr., 2019)
Inoviranje podatki s	Obseg v katerem se podatki uporabljajo za večanje dodane vrednosti podjetja in za inovacije (izdelki, storitve, ...)	(Babu idr., 2021)

**Tabela 3: Kriteriji, povezani s tehnološkimi zmogljivostmi**

Kriterij	Opis kriterija	Avtor(ji)
Tehnologije	Vrstva in obseg tehnologij, ki se uporabljajo za podporo poslovanja	(Moonen idr., 2019)
Orodja	Vrstva in obseg analitičnih orodij, uporabljenih za analizo podatkov	(Deloitte, 2021; Moonen idr., 2019; Parra idr., 2019)
E-poslovanje	Obseg prehoda na e-poslovanje in elektronsko podpisovanje dokumentov	Dodal avtor tega prispevka

## 5 Zaključek

Podatki postajajo nepogrešljiv vir za nadaljnji digitalni razvoj organizacije in osnova za podatkovno vodeno organizacijo. Če se s podatki upravlja slabo, lahko to privede do poznega odzivanja na potrebe trga, napačnih ali zavajajočih informacij in lahko vpliva na točnost odločitev za pravočasno prilagajanje nenehnim spremembam okolja. V prispevku smo obravnavali problem ocenjevanja podatkovne zrelosti MSP. Na podlagi pregleda literature nismo našli modela, ki bi MSP omogočal celovito oceno podatkovne zrelosti. V ta namen smo pregledali literaturo in opredelili nabor kriterijev, ki jih bomo uporabili za izgradnjo modela za oceno podatkovne zrelosti MSP. Predlagani nabor kriterijev je trenutno v fazi validacije, ki je podprta z izvedbo pol-strukturiranih intervjujev. Namen intervjujev je dodati manjkajoče kriterije, ki smo jih morda spregledali ali pa v literaturi niso navedeni. Na podlagi odgovorov iz intervjujev, bomo kriterije dodali ali odstranili, da sestavimo končni seznam kriterijev, preden začnemo razvijati model za oceno podatkovne zrelosti MSP. Ko bomo z intervjuji kriterije potrdili, bomo razvili model za oceno podatkovne zrelosti MSP.

## Zahvala

Raziskavo je podprla Javna agencija za raziskovalno dejavnost RS: program št. P5-0018 »Sistemi za podporo odločanju v digitalnem poslovanju« in financiranje podiplomskih raziskav za mlade raziskovalce št. 54752-0586-21.

## Literatura

- Accenture. (2018). Becoming a data-driven enterprise: Data Industrialization. <https://www.accenture.com/us-en/insights/technology/data-industrialization>
- 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>
- Alhwamdeh, H. M., & Alsmairat, M. A. K. (2019). Strategic Decision Making and Organization Performance: A Literature Review. International Review of Management and Marketing, 9(4), 95–99. <https://doi.org/10.32479/IRMM.8161>
- Alsheiabni, S., Cheung, Y., & Messom, C. (2019). Association for Information Systems Association for Information Systems AIS Electronic Library (AISel) AIS Electronic Library (AISel) Towards An Artificial Intelligence Maturity Model: From Science Towards An Artificial Intelligence Maturity Model: From Science Fiction To Business Facts Fiction To Business Facts. Pacific Asia Conference on Information Systems (PACIS), 6–15. <https://core.ac.uk/download/pdf/301391799.pdf>
- Areerakulkarn, N., & Pongpech, W. A. (2021). A Dempster-Shafer Big Data Readiness Assessment Model. International Conference on Enterprise Information Systems, ICEIS - Proceedings, 2, 581–585. <https://doi.org/10.5220/0010506205810585>
- Baars, T., Mijnhardt, F., Vlaanderen, K., & Spruit, M. (2016). An analytics approach to adaptive maturity models using organizational characteristics. Decision Analytics, 3(1), 5. <https://doi.org/10.1186/s40165-016-0022-1>
- 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>
- Bohanec, M., Martin, Ž., Vladislav, R., Ivan, B., & Blaž, Z. (2013). DEX Methodology: Three Decades of Qualitative Multi-Attribute Modeling. Informatica, 37(1), 49–54. <https://www.informatica.si/index.php/informatica/article/viewFile/433/437>
- Boonsiritomachai, W., McGrath, G. M., & Burgess, S. (2016). Exploring business intelligence and its depth of maturity in Thai SMEs. Cogent Business & Management, 3(1), 1220663. <https://doi.org/10.1080/23311975.2016.1220663>
- 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\\_Consequences\\_Completed\\_Research\\_Paper/links/564a11b908ae44e7a28d9146/Information-Management-Capabilities-Antecedents-And-Conseq](https://www.researchgate.net/profile/Rafael-Brinkhues/publication/263272671_Information_Management_Capabilities_Antecedents_An_Consequences_Completed_Research_Paper/links/564a11b908ae44e7a28d9146/Information-Management-Capabilities-Antecedents-And-Conseq)
- Brous, P., Janssen, M., & Vilimko-Heikkinen, R. (2016). Coordinating Decision-Making in Data Management Activities: A Systematic Review of Data Governance Principles BT - Electronic Government (H. J. Scholl, O. Glassey, M. Janssen, B. Klievink, I. Lindgren, P. Parycek, E. Tambouris, M. A. Wimmer, T. Janowski, & D. Sá Soares (ur.); str. 115–125). Springer International Publishing.
- Carnicer, I., González-Gaya, C., & Rosales, V. F. (2021). The Transformation Process of the University into a Data Driven Organisation and Advantages It Brings: Qualitative Case Study. V Sustainability (Let. 13, Številka 22). <https://doi.org/10.3390/su132212611>
- Charnley, F., Tiwari, D., Hutabarat, W., Moreno, M., Okorie, O., & Tiwari, A. (2019). Simulation to Enable a Data-Driven Circular Economy. V Sustainability (Let. 11, Številka 12). <https://doi.org/10.3390/su11123379>
- Chen, L., & Nath, R. (2018). Business analytics maturity of firms: an examination of the relationships between managerial perception of IT, business analytics maturity and success. Information Systems Management, 35(1), 62–77. <https://doi.org/10.1080/10580530.2017.1416948>

- Chonsawat, N., & Sopadang, A. (2019). The Development of the Maturity Model to evaluate the Smart SMEs 4.0 Readiness. Proceedings of the International Conference on Industrial Engineering and Operations Management, 354–363.  
<http://www.ieomsociety.org/ieom2019/papers/97.pdf>
- CMMI Institute. (2019). Data Management Maturity Model (DMM).  
<https://stage.cmmiinstitute.com/getattachment/cb35800b-720f-4afe-93bf-86cccfb1fb17/attachment.aspx>
- 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>
- Colli, M., Madsen, Ö., Berger, U., Møller, C., Wæhrens, B. V., & Bockholt, M. (2018). Contextualizing the outcome of a maturity assessment for Industry 4.0. *IFAC-PapersOnLine*, 51(11), 1347–1352. <https://doi.org/https://doi.org/10.1016/j.ifacol.2018.08.343>
- Dąbrowska, J., Almpanopoulou, A., Brem, A., Chesbrough, H., Cucino, V., Di Minin, A., Giones, F., Hakala, H., Marullo, C., Mention, A.-L., Mortara, L., Nørskov, S., Nylund, P. A., Oddo, C. M., Radziwon, A., & Ritala, P. (2022). Digital transformation, for better or worse: a critical multi-level research agenda. *R&D Management*, 52(5), 930–954.  
<https://doi.org/https://doi.org/10.1111/radm.12531>
- Deloitte. (2021). Demystifying data 2021 - Unlocking the benefits of data maturity and machine learning in Australia and New Zealand.  
<https://www2.deloitte.com/content/dam/Deloitte/au/Documents/Economics/deloitte-au-dae-demystifying-data-2021-301121.pdf>
- Farah, B. (2017). A Value Based Big Data Maturity Model. *Journal of Management Policy and Practice*, 18(1), 11–18. [http://www.na-businesspress.com/JMPP/FarahB\\_Web18\\_1\\_.pdf](http://www.na-businesspress.com/JMPP/FarahB_Web18_1_.pdf)
- 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>
- Gudfinnsson, K., & Strand, M. (2017). Challenges with BI adoption in SMEs. 2017 8th International Conference on Information, Intelligence, Systems & Applications (IISA), 1–6.  
<https://doi.org/10.1109/IISA.2017.8316407>
- Gür, I., Spiekermann, M., Arbter, M., & Otto, B. (2021). Data Strategy Development: A Taxonomy for Data Strategy Tools and Methodologies in the Economy. *Wirtschaftsinformatik 2021 Proceedings*, 1–16.  
<https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1015&context=wi2021>
- Hagen, J., & Hess, T. (2020). Linking Big Data and Business: Design Parameters of Data-Driven Organizations. Conference of the Association-for-Information-Systems (AMCIS), 1–10.  
[https://www.researchgate.net/profile/Janine-Hagen/publication/343549422\\_Linking\\_Big\\_Data\\_and\\_Business\\_Design\\_Parameters\\_of\\_Data-Driven\\_Organizations/links/5f3137ff458515b729123254/Linking-Big-Data-and-Business-Design-Parameters-of-Data-Driven-Organizations.pdf](https://www.researchgate.net/profile/Janine-Hagen/publication/343549422_Linking_Big_Data_and_Business_Design_Parameters_of_Data-Driven_Organizations/links/5f3137ff458515b729123254/Linking-Big-Data-and-Business-Design-Parameters-of-Data-Driven-Organizations.pdf)
- Halper, F. (2020). TDWI Analytics Maturity Model Assessment Guide TDWI RESEARCH Introduction 4. [https://go.tdwi.org/rs/626-EMC-557/images/TDWI\\_Analytics-Maturity-Model-Assessment-Guide\\_2020.pdf](https://go.tdwi.org/rs/626-EMC-557/images/TDWI_Analytics-Maturity-Model-Assessment-Guide_2020.pdf)
- Hanelt, A., Bohnsack, R., Marz, D., & Antunes Marante, C. (2021). A Systematic Review of the Literature on Digital Transformation: Insights and Implications for Strategy and Organizational Change. *Journal of Management Studies*, 58(5), 1159–1197.  
<https://doi.org/https://doi.org/10.1111/joms.12639>
- Haucap, J. (2019). Competition and Competition Policy in a Data-Driven Economy. *Intereconomics*, 54(4), 201–208. <https://doi.org/10.1007/s10272-019-0825-0>
- Heinrich, B. (2017). Requirements for Data Quality Metrics. *Journal of Data and Information Quality*, 9(2), 1–29. [https://epub.uni-regensburg.de/36889/1/Requirements\\_for\\_Data\\_Quality\\_Metrics.pdf](https://epub.uni-regensburg.de/36889/1/Requirements_for_Data_Quality_Metrics.pdf)

- Hevner, A. R. (2007). A Three Cycle View of Design Science Research. *Scandinavian Journal of Information Systems*, 19(2), 1–6.  
<https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1017&context=sjis>
- Hevner, A. R., March, S. T., Park, J., & Ram, S. (2004). Design Science in Information Systems Research. *MIS Quarterly*, 28(1), 75–105. <https://doi.org/10.2307/25148625>
- Hornick, M. (2020). A Data Science Maturity Model for Enterprise Assessment. <https://www.oracle.com/a/devo/docs/data-science-maturity-model.pdf>
- IBM. (2007). IBM data governance maturity model. <https://www.lightsondata.com/data-governance-maturity-models-ibm/>
- Iqbal, R., Yuda, P., Aditya, W., Hidayanto, A. N., Wuri Handayani, P., & Harahap, N. C. (2019). Master data management maturity assessment: Case study of XYZ company. 2nd International Conference on Applied Information Technology and Innovation (ICAITI), 133–139. <https://doi.org/10.1109/ICAITI48442.2019.8982123>
- Karaboga, H. A., Zehir, C., & Karaboga\*, T. (2019). Big Data Analytics And Firm Innovativeness: The Moderating Effect Of Data-Driven Culture. V M. Özşahin & T. Hıdırlar (Ur.), Proceedings of the 14th International Strategic Management Conference & 8th International Conference on Leadership, Technology, Innovation and Business Management (Joint Conference ISMC & ICLTIBM 2018) (str. 526–535). Future Academy.  
<https://doi.org/10.15405/EPSBS.2019.01.02.44>
- Kljajić 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>
- Limpeeticharoenchot, S., Cooharajanokane, N., Chavarnakul, T., Charoenruk, N., & Atchariyachanvanich, K. (2022). Adaptive big data maturity model using latent class analysis for small and medium businesses in Thailand. *Expert Systems with Applications*, 206, 117965. <https://doi.org/https://doi.org/10.1016/j.eswa.2022.117965>
- Llave, M. R., Hustad, E., & Olsen, D. H. (2018). Creating Value from Business Intelligence and Analytics in SMEs: Insights from Experts VOIL-Virtual Open Innovation Lab View project Call for Papers: Special issue at Scandinavian Journal of Information Systems on Enterprise Systems View project. Twenty-fourth Americas Conference on Information Systems, 1–10. [https://www.researchgate.net/profile/Marilex-Llave/publication/330765646\\_Creating\\_Value\\_from\\_Business\\_Intelligence\\_and\\_Analytics\\_in\\_SMEs\\_Insights\\_from\\_Experts/links/5c5381d292851c22a39f5637/Creating-Value-from-Business-Intelligence-and-Analytics-in-SMEs-Insights-from-Experts.pdf](https://www.researchgate.net/profile/Marilex-Llave/publication/330765646_Creating_Value_from_Business_Intelligence_and_Analytics_in_SMEs_Insights_from_Experts/links/5c5381d292851c22a39f5637/Creating-Value-from-Business-Intelligence-and-Analytics-in-SMEs-Insights-from-Experts.pdf)
- Maroufkhan, P., Wan Ismail, W. K., & Ghobakhloo, M. (2020). Big data analytics adoption model for small and medium enterprises. *Journal of Science and Technology Policy Management*, 11(4), 483–513. <https://doi.org/10.1108/JSTPM-02-2020-0018>
- Mittal, S., Khan, M. A., Romero, D., & Wuest, T. (2018). A critical review of smart manufacturing & Industry 4.0 maturity models: Implications for small and medium-sized enterprises (SMEs). *Journal of Manufacturing Systems*, 49, 194–214. <https://doi.org/10.1016/j.jmsy.2018.10.005>
- Mohamed, M., & Weber, P. (2020). Trends of digitalization and adoption of big data analytics among UK SMEs: Analysis and lessons drawn from a case study of 53 SMEs. *International Conference on Engineering, Technology and Innovation (ICE/ITMC 2020)*, 1–6. <https://doi.org/10.1109/ICE/ITMC49519.2020.9198545>
- 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>
- Nijzink, H. J. (2020). Data-driven Decision-making Maturity. <http://essay.utwente.nl/85376/>
- Nkwabi, J., Mboya, L. B., & Nkwabi, J. M. (2019). A Review of Factors Affecting the Growth of Small and Medium Enterprises (SMEs) in Tanzania. *European Journal of Business and Management*, 11(33), 1–8. <https://doi.org/10.7176/EJBM/11-33-01>

- Noonpakdee, W., Phothichai, A., & Khunkornsiri, T. (2018). Big data implementation for small and medium enterprises. 2018 27th Wireless and Optical Communication Conference (WOCC), 1–5. <https://doi.org/10.1109/WOCC.2018.8372725>
- 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>
- Omar, R., Takim, R., & Nawawi, A. H. (2012). Measuring of Technological Capabilities in Technology Transfer (TT) Projects. *Asian Social Science*, 8(15), 211–221. <https://doi.org/10.5539/ASS.V8N15P211>
- 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>
- Pora, U., Gerdtsri, N., Thawesaengskulthai, N., & Triukose, S. (2022). Data-Driven Roadmapping (DDRM): Approach and Case Demonstration. *IEEE Transactions on Engineering Management*, 69(1), 209–227. <https://doi.org/10.1109/TEM.2020.3005341>
- Sadiq, R. B., Safie, N., Abd Rahman, A. H., & Goudarzi, S. (2021). Artificial intelligence maturity model: a systematic literature review. *PeerJ Computer Science*, 7, e661. <https://doi.org/10.7717/peerj-cs.661>
- Santos, M. Y., Carvalheira, A., & Araujo, A. T. de. (2015). A data-driven analytics approach in the study of pneumonia's fatalities. 2015 IEEE International Conference on Data Science and Advanced Analytics (DSAA), 1–10. <https://doi.org/10.1109/DSAA.2015.7344868>
- Sekarhati, D. K. S., Nefiratika, A., Hidayanto, A. N., Budi, N. F. A., & Solikin. (2019). Online Travel Agency (OTA) Data Maturity Assessment: Case Study PT Solusi Awan Indonesia -“Flylist”. 2019 International Conference on Information Management and Technology (ICIMTech), 1, 492–497. <https://doi.org/10.1109/ICIMTech.2019.8843728>
- Sinaeepourfard, A., García, J., Maspí-Bruin, X., & Marín-Tordera, E. (2016). A comprehensive scenario agnostic Data LifeCycle model for an efficient data complexity management. 2016 IEEE 12th International Conference on e-Science (e-Science), 276–281. <https://doi.org/10.1109/eScience.2016.7870909>
- Spruit, M., & Pietzka, K. (2015). MD3M: The master data management maturity model. *Computers in Human Behavior*, 51, 1068–1076. <https://doi.org/10.1016/j.chb.2014.09.030>
- Stanford. (2013). Data Governance Maturity Model. Thesis. <https://hnu.edu/wp-content/uploads/2020/03/Data-Governance-Maturity-Model.pdf>
- Vial, G. (2019). Understanding digital transformation: A review and a research agenda. *The Journal of Strategic Information Systems*, 28(2), 118–144. <https://doi.org/https://doi.org/10.1016/j.jsis.2019.01.003>
- Virkkala, P., Saarela, M., Hänninen, K., & Simunaniemi, A.-M. (2020). Business Maturity Models for Small and Medium-Sized Enterprises: A Systematic Literature Review. *Technology, Innovation and Industrial Management (TIIM)*, 523–536. <http://www.toknowpress.net/ISBN/978-961-6914-26-0/154.pdf>

