

# VLOGA PODATKOV V SODOBNI ORGANIZACIJI

BLAŽ GAŠPERLIN IN MIRJANA KLJAJIĆ BORŠTNAR

Univerza v Mariboru, Fakulteta za organizacijske vede, Kranj, Slovenija  
E-pošta: blaz.gasperlin1@um.si, mirjana.kljajic@um.si

**Povzetek** Digitalna preobrazba je vzpodbudila nastajanje novih izdelkov, storitev in poslovnih modelov ter s tem nastanek povsem digitalnih okolij. Hiter razvoj in dostopnost digitalnih tehnologij sta povečala tudi količino podatkov in informacij, ki postajajo vedno bolj pomemben strateški vir in spodbujevalec sprememb sodobnih organizacij. Podatki ponujajo priložnost za ustvarjanje novih vpogledov, spoznanj in ključno podlago za sprejemanje kakovostnih odločitev. Kljub naraščanju pomembnosti podatkov organizacije premalo izkoriščajo njihovo vrednost ali pa jim primanjkuje znanj za njihovo celovito obvladovanje. Zaostajajo predvsem majhna in srednja podjetja, ki nimajo dovolj finančnih in kadrovskih virov. V prispevku izpostavimo pomembnost in vlogo podatkov v sodobni organizaciji. Najprej izpostavimo nekaj vlog in modelov podatkovnega upravljanja, zaključimo pa z modeli podatkovne zrelosti. Ugotavljamo, da podatki pomembno vplivajo na odločitveni proces in so velik spodbujevalec digitalne preobrazbe. Obvladovanje podatkov je še vedno največji problem majhnih in srednjih podjetij, zato bo tu potreben nadaljnji dvig podatkovne kulture, kompetenc in opredelitev podatkovne strategije.

#### Ključne besede:

digitalna preobrazba, podatki, podpora odločanju, podatkovna znanost, podatkovna zrelost

# THE ROLE OF DATA IN A MODERN ORGANIZATION

BLAŽ GAŠPERLIN & MIRJANA KLJAJIĆ BORŠTNAR

University of Maribor, Faculty of Organizational Sciences, Kranj, Slovenia  
E-mail: blaz.gasperlin1@um.si, mirjana.kljajic@um.si

**Abstract** Digital transformation (DT) induced the creation of new digital products, services, and business models, and creation of digital environments. The rapid development and availability of digital technologies has also increased the amount of data and information, which are becoming an important strategic resource and driver of change in modern organizations. Data provides an opportunity to create new insights and basis for a quality based decisions. Despite the growing importance of data, organizations underutilize their value and have a lack of skills to manage them comprehensively. The organizations lagging the most are small and medium-sized enterprises, due to insufficient financial and human resources. The paper highlights the important role of data in a modern organization. We first present some of the roles and data governance models, and conclude with the data maturity models. We found that data have a high impact on the decision-making process and are a major driver of DT. Data governance is still the biggest problem among the SMEs. Further steps require increase of data culture, competencies and definition of a data strategy.

**Keywords:**

digital  
transformation,  
data,  
decision  
support,  
data  
science,  
data  
maturity

## 1 Uvod

V času, ki ga zaznamujejo hiter razvoj in dostopnost digitalne tehnologije, skokovito naraščanje količine podatkov in informacij, smo se kot posamezniki, organizacije in družba znašli v procesu preobrazbe, ki ji pravimo digitalna preobrazba. Slednjo v večini povezujemo z digitalizacijo organizacij, selitvijo obstoječih poslovnih modelov v digitalni svet (splet) ter inoviranjem proizvodov, storitev in poslovnih modelov. Danes je že jasno, da se preobrazba lahko zgodi, če je organizacija sposobna te (pogosto hitre) spremembe sprejeti, če omogoča primerno organizacijsko klimo (odprto komuniciranje, eksperimentiranje, toleriranje napak, agilnost), vlaga v razvoj zaposlenih, učinkovito upravlja z znanjem in sprejema informirane in pravočasne odločitve (Kljajić Borštnar in Pucihar, 2021). Raziskovanje dejavnikov, ki spodbujajo, omogočajo in zavirajo digitalno preobrazbo, do teoretičnih okvirjev in praktičnih modelov digitalne zrelosti, s katerimi skušamo ugotoviti stanje organizacij in jim pri preobrazbi pomagati, je vse bolj aktualno. Digitalna zrelost organizacij se nanaša na oceno sposobnosti in pripravljenosti organizacij po različnih vidikih. Pomemben del digitalne zrelosti organizacije se nanaša na sposobnost sprejemanja odločitev, ki so utemeljene na podatkih. Čeprav se je v preteklih letih veliko pozornosti usmerjalo na samo podatkovno analitiko in podatkovne tehnologije, se je zanemarjalo organizacijski kontekst. Pričakovanja, da bodo posamezniki v vlogah poslovnih in podatkovnih analitikov ter podatkovnih znanstvenikov organizacijam prinesli velike dobičke, so se razblinila. Problem, s katerim se sooča večina organizacij, je v tem, da so s podatki zasuti, hkrati pa jim informacij in znanja še vedno primanjkuje (Ng in Liu, 2000).

### 1.1 Opredelitev problema

Odločanje je miselni proces, v katerem človek zbira podatke in informacije, jih analizira ter pridobljeno znanje uporabi pri izbiri ene izmed alternativ, ki najbolje izpolnjuje zastavljene cilje (Simon, 1960). Odločanje v organizacijskih sistemih je kompleksen proces, saj poleg naštetega vključuje skupino ljudi, ki imajo lahko tudi različna znanja, razumevanje problema in interese (Kljajić Borštnar idr., 2011). Odločitve se sprejemajo na različnih ravneh (operativni, taktični in strateški ravni), zato so različno kompleksne in zahtevajo različne pristope, imajo pa tudi različno usodne posledice. Nekatere posledice lahko enostavno odpravimo, druge pa so tudi nepopravljive. Medtem ko je osnovna naloga organizacije zagotavljanje dodane

vrednosti za stranke (v proizvodnih podjetjih so to izdelki in storitve, v storitvenih podjetjih in organizacijah pa storitve), je osnovna naloga informacijskega sistema zajem, obdelava in hramba podatkov ter dostopanje, analiza in zagotavljanje informacij za potrebe izvajanja procesov in odločanja. Podatki so torej osnovna surovina informacijskega procesa in so neločljivo povezani z odločitvenim procesom, ta pa s procesom upravljanja. Uspešnost in učinkovitost upravljanja organizacije merimo z razkorakom med zastavljenimi cilji in realizacijo (Baker, 1995; Ramaprasad, 1983). Temu rečemo tudi povratna informacija. Čeprav imamo danes na voljo ogromno podatkov, pa še vedno velja, da nam primanjkuje informacij in znanja (Brynjolfsson idr., 2011; McAfee in Brynjolfsson, 2012; Ng in Liu, 2000). To pomeni, da kljub poplavi podatkov organizacije praviloma le-teh ne znajo spremeniti v uporabne informacije in znanje. Podatki so različno dostopni, hranimo jih na različnih mestih in formatih, v različnih časovnih periodah, v različnih sistemih itd. Medtem ko je na operativni ravni odločanje preprosteje (usmerjeno je v bližnjo prihodnost, ki je bolj gotova), na voljo pa imamo dobro strukturirane podatke, ki jih zajemamo sami, so na strateškem nivoju podatki manj strukturirani, pogosto prihajajo iz zunanjih virov, zato so manj zanesljivi.

Trenutna paradigma podatkovno vodene organizacije (angl. data-driven organization) sloni na ideji, da so podatki pomemben, celo strateški vir organizacije in zato pomembno prispevajo k dodani vrednosti. Iz tega razloga so postavljena velika pričakovanja do zaposlenih, ki se ukvarjajo s podatki, na primer podatkovnimi analitiki in podatkovnimi znanstveniki. Vendar pa v praksi opazimo, da prispevek podatkov k dodani vrednosti organizacije ni samoumeven. Vrednost, ki naj bi jo nosili podatki, ni odvisna samo od podatkovnih analitikov, pač pa je odvisna od razumevanja kompleksnih organizacijskih procesov, kakovosti podatkov, organizacijske kulture in sodobnih metod ter pristopov k analizi podatkov, ki skupaj lahko pretvorijo podatke v poslovno vrednost in prednost. Ta problem je raziskan predvsem v večjih podjetjih, vendar pa vemo, da je stanje v malih in srednje velikih podjetjih (MSP) le še bolj dramatično. Medtem ko se v velikih podjetjih soočajo z izzivi organizacijskih sprememb (obstoječi informacijski sistemi, agilnost, komuniciranje ipd.), se v MSP soočajo s pomanjkanjem virov (finančnih, kadrovskih in časovnih). Digitalizacijo je tudi v MSP dodobra pospešila epidemija COVID-19, na katero so se bila podjetja primorana odzvati. Digitalne tehnologije niso bile nikoli tako dostopne, kot so sedaj, vrzel pa se kaže v sposobnosti organizacije, da te spremembe ponotranji in se prilagodi tudi na nivoju obvladovanja in upravljanja

podatkov. Izhajamo iz teze, da je reševanje kompleksnih organizacijskih problemov in izzivov moč učinkovito podpreti z uporabo naprednih tehnologij in metod podatkovne analitike, upošteva naslednje predpostavke: 1) da v organizaciji znamo postaviti prava vprašanja, 2) imamo kakovostne podatke in 3) se na podlagi novih spoznanj učimo (podpiramo organizacijsko učenje).

Podatkovna strategija mora slediti jasno artikuliranim ciljem organizacije. To pomeni, da mora poslovodstvo razumeti probleme in izzive ter znati postaviti prava vprašanja. Odgovori na ta vprašanja pa morajo biti utemeljeni na podatkih. Temu rečemo tudi, da je podatkovna analitika osnovana na odločanju (angl. Decision-driven data analytics), namesto da so odločitve vodene na podlagi (obstojećih) podatkov. Na prvi pogled se zdi trditev v nasprotju z idejo, da lahko iz podatkov pridobimo skrito znanje, vendar pa je potreben celovit premislek o poslovanju in odločanju. Podatki niso edini, ki hranijo znanje. Znanje v organizaciji se hrani v timu, procesih, podatkih (za katere vemo, da obstajajo) in skritih podatkih (angl. dark data – ti podatki v organizaciji obstajajo, vendar zanje ne vemo), modelih in zgodovini. Zato je pomembno, da razumemo obvladovanje in upravljanje podatkov celovito v kontekstu organizacije in širšega poslovnega ekosistema ter razumevanju moči in nemoči tehnologije.

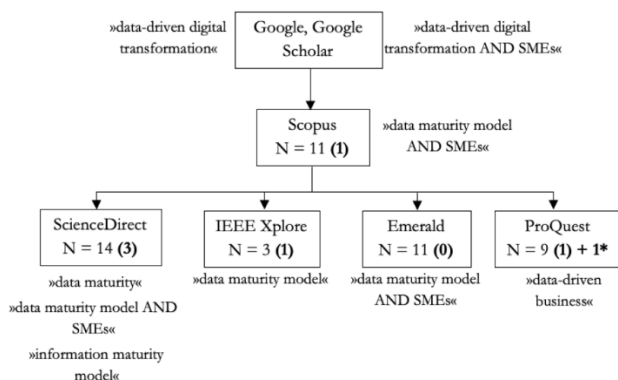
Namen prispevka je opredeliti vlogo in pomen podatkov v sodobnih organizacijah. V ta namen smo opredelili osnovne pojme, koncepte na področju podatkov in podatkovne tehnologije ter raziskali zrelost organizacij za učinkovito upravljanje in uporabo podatkov.

## **2 Metodologija**

Cilj prispevka je pripraviti celovit pregled področja upravljanja podatkov v sodobni organizaciji. V ta namen smo pregledali literaturo na področju življenjskega cikla upravljanja podatkov, podatkovnih tehnologij, vloge podatkov v digitalni preobrazbi in modelov podatkovne zrelosti.

Za pregled modelov podatkovne zrelosti in ostalih vlog, ki nastajajo na področju podatkovne znanosti, smo kot raziskovalni pristop uporabili pregled literature. Najprej smo naredili nekaj poizvedb preko iskalnikov Google in Google Scholar, da smo dobili splošen pregled področja in obstoječe literature modelov podatkovne

zrelosti. Za iskanje smo uporabili iskalni poizvedbi »data-driven digital transformation« in »data-driven digital transformation AND SMEs«. Da bi iskanje omejili na modele podatkovne zrelosti in majhna ter srednja podjetja, smo z iskanjem nadaljevali v podatkovni bazi Scopus, kjer smo na podlagi naslova in povzetka za nadaljnji pregled izbrali 11 člankov. Ker se modeli na tem področju šele dobro razvijajo, smo iskanje razširili z vključitvijo drugih podatkovnih baz (ScienceDirect, IEEE Explore, ProQuest). V primeru ScienceDirect smo za podrobnejši pregled izbrali 14 člankov, v primeru IEEE Explore smo od osmih izbrali 3 za nadaljnji pregled, v Emeraldu smo jih za nadaljnji pregled izbrali 11, v podatkovni bazi ProQuest pa skupaj 9 člankov. Nekateri izmed člankov niso bili dostopni, zato smo takšne članke skušali poiskati preko drugih repozitorijev, kot je na primer ResearchGate. Za izbiro končnega števila smo izključili članke, pri katerih celotna vsebina ni bila na voljo, niso bili napisani v angleščini ali pa niso imeli povezave z modeli podatkovne zrelosti. Uporabili smo tudi metodo snežne kepe in naredili nadaljnji pregled referenc v posameznih člankih, kar je rezultiralo v enem dodatnem viru.



Slika 1: Proces pregleda literature

Tako smo na koncu od skupno 48 identificirali 7 relevantnih člankov, ki predstavljajo modele podatkovne zrelosti. Slika 1 prikazuje proces pregleda s podatkovnimi bazami in pripadajočimi iskalnimi poizvedbami pri vsaki bazi. Številke izven oklepajev predstavljajo število zadetkov relevantnih člankov, ki smo jih podrobneje analizirali, odebeljene številke v oklepajih pa število končno izbranih člankov, relevantnih za našo raziskavo.

### 3 Podatkovno vodena organizacija

#### 3.1 Vloga podatkov v digitalni preobrazbi

Digitalna preobrazba neprestano sili organizacije k spreminjanju njihovih poslovnih procesov, izdelkov in storitev ter k drugačnemu načinu poslovanja. Pojav in povečevanje raznovrstnosti digitalnih tehnologij, kot so internet stvari, visokozmogljivo računalništvo, umetna inteligenca in analitika masovnih podatkov (angl. Big Data analytics, High Performance Data Analytics), napreduje in zagotavlja potrebno povezljivost in infrastrukturo. Takšen nabor tehnologij organizacijam olajša vsakodnevno poslovanje in omogoča bolj tekočo izvedbo poslovnih procesov. S tem se organizacije bližajo tudi k uresničevanju digitalne preobrazbe in k ustvarjanju povsem digitalnega okolja. Vendar pa digitalne tehnologije niso edino gonilo digitalne preobrazbe (Marolt idr., 2018). Upoštevati je treba tudi druge organizacijske dejavnike, kot so digitalne kompetence, vodenje in podpora posloводства (angl. management support), jasno opredeljena strategija in organizacijska kultura (Gašperlin idr., 2021). Pomemben zunanji dejavnik predstavljajo vladne in raziskovalne institucije, ki organizacijam zagotavljajo potrebno podporo preko različnih iniciativ in združenj (big-data-value.eu; edincubator.eu) ter projektov (I-BiDaaS; SMEDATA II), s čimer jih spodbujajo k doseganju digitalne preobrazbe.

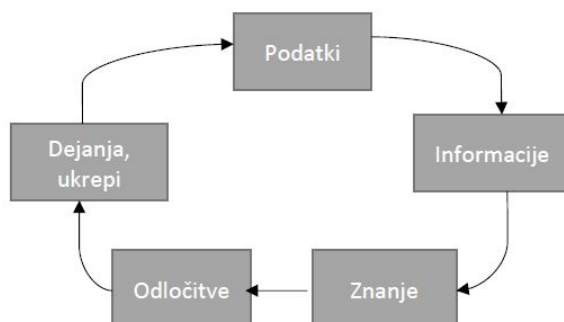
Zagotovljena povezljivost ob uporabi digitalnih tehnologij povzroča ogromne količine podatkov (angl. volume), ustvarjenih z različnimi podatkovnimi viri (angl. variety), kot so podatkovne baze organizacij in njihovi notranji poslovni sistemi, podatkovna skladišča, repozitoriji z dostopom v oblaku in strojni podatki, ki jih zagotavljajo senzorji naprav. Podatki se generirajo tudi z različno frekvenco ali hitrostjo (angl. velocity) in imajo različno stopnjo verodostojnosti (angl. veracity). Poleg tega zbrani podatki organizacijam zagotavljajo tudi vrednost (Baesens idr., 2016). Teh pet elementov (obseg podatkov, raznovrstnost, hitrost, verodostojnost in vrednost) skupaj tvori širše znan pojav, znan kot masovni ali velepodatki (angl. Big Data). Takšna raznolikost podatkov organizacijam ponuja možnost za ustvarjanje novih izdelkov, storitev ter poslovnih modelov, ki temeljijo izključno na podatkih (Fruhworth idr., 2020). Poslovni model pri tem predstavlja osnovo za ustvarjanje nove vrednosti (izdelkov ali storitev) ob uporabi digitalnih tehnologij (Verhoef idr., 2019).

Evropska komisija (European Commission, 2020) je v letu 2020 predstavila in sprejela evropsko podatkovno strategijo (angl. European strategy for data). Poudarila je pomen digitalnih tehnologij, kjer vloga podatkov kot gonilne sile narašča in je v ospredju digitalne preobrazbe. Podatki so tako rekoč postali pomemben strateški vir in osnova za izboljšanje obstoječih ter ustvarjanje novih izdelkov in storitev ter nudijo podrobnejši pregled nad strankami, partnerji in trgi (Hartmann idr., 2016; Marchildon idr., 2018). Enak trend je opaziti v poročilu raziskovalne institucije IDC (IDC, 2020), kjer le-ta ocenjuje, da se bo do leta 2025 generiralo do 175 zetabajtov novih podatkov. To je tudi v skladu z izjavo gospe Kate Smaje (višje partnerice raziskovalne institucije McKinsey), kjer vodilne organizacije za doseganje digitalne preobrazbe poleg tehnologije, procesov in ljudi vlagajo tudi v podatke (McKinsey, 2020). Slednje jim omogoča sprejemanje boljših odločitev in hitrejša popravke prejšnjih. Za sprejemanje pravih odločitev bi morale organizacije uporabljati analitiko (masovnih) podatkov. Medtem ko se podatkovna analitika nanaša na proces analize katere koli oblike podatkov (strukturirani, polstrukturirani in nestrukturirani podatki) z namenom ustvarjanja informacij (Vijesh Joe idr., 2020), pa se analitika masovnih (vele) podatkov (angl. Big Data analytics) osredotoča na identifikacijo skritih vzorcev iz zelo velikih, nestrukturiranih podatkov in podatkov, ki se ustvarjajo z visoko hitrostjo (Loebbecke in Picot, 2015; Maroufkhani idr., 2020). Vsaka organizacija bi morala imeti razvite tudi določene zmogljivosti (orodja, znanja, veščine, tehnologijo), s katerimi lahko identificira in izrabi vrednost zbranih podatkov (Ciampi idr., 2021). Avtorji (Baesens idr., 2016) poudarjajo, da morajo biti podatki tudi dovolj kakovostni. Čeprav so se tudi pretekle študije osredotočale na koncept organizacije, katere delovanje in poslovanje temeljita na podatkih (angl. data-driven organization), je bilo zaznati manj raziskav, ki bi se osredotočile na vpliv vrednosti podatkov na poslovni model organizacij in perspektivo odločanja na podlagi podatkov.

(Sorescu, 2017) je proučevala, kako lahko organizacije izkoriščajo notranje in zunanje podatke za ustvarjanje novih poslovnih modelov. Osredotočila se je predvsem na primere velikih podjetij, kot so Zara, Amazon in FitBit. Zarin poslovni model temelji na sprotni analizi podatkov modnih trendov, ki jih zagotovijo neodvisni prodajalci, drugi del podatkov pa podjetje pridobi preko strank, ko te opravijo nakup. Podjetje tako hitro prilagodi modni trend in ponudbo oblačila, hkrati pa ohranja nizko zalogo. Podobno deluje tudi podjetje Amazon, ki podatke pridobiva na podlagi analize o iskanju izdelkov preko spletne trgovine in opravljenih nakupih strank. Strankam



potem ponudi bolj prilagojene izdelke. Podjetje FitBit pa podatke zbira preko naprav za spremljanje športne aktivnosti. Ti podatki se lahko potem uporabijo pri oblikovanju zdravstvenega profila, kjer so združeni podatki vitalnih funkcij in zunanji podatki, zbrani preko FitBit naprave, končni rezultat pa je zagotovljena boljša oskrba pacienta. Tudi Mitra, Gaur in Giacosa (2019) vidijo podatke kot ključni dejavnik za začetek procesa digitalne preobrazbe. Kot prvi korak izpostavljajo opredelitev podatkovne strategije, drugi korak pa je spodbujanje miselnosti (kulture), ki temelji na podatkih. Podatkovna kultura obravnava podatke kot oprijemljiv vir organizacije in določa, v kolikšni meri se organizacijske odločitve sprejemajo na podlagi pridobljenih podatkov (Mikalef idr., 2019). Slika 2 prikazuje osnovno informacijsko vrednostno verigo. Ko se podatki zberejo in oblikujejo v informacije, lahko s pomočjo podatkovne analitike pridobimo in ustvarimo znanje. Na podlagi pridobljenega znanja iz informacij lahko sprejemamo na podatkih utemeljene odločitve (angl. data driven decision-making). Na podlagi pridobljenih spoznanj in odločitev pa ustvarjamo nove izdelke ali storitve ter spreminjamo trenutni poslovni model ali pa ustvarimo novega.



**Slika 2: Osnovna informacijska vrednostna veriga**

Vir: prirejeno po (Abbasi idr., 2016)

Organizacijo, ki svoje tradicionalno poslovanje pretvori v poslovanje in odločitve, ki temeljijo izključno na podatkih, in sicer z osredotočenostjo na zbiranju, shranjevanju in analiziranju podatkov v realnem času, kot tudi na obdelavi podatkov za izdelavo in uporabo napovednih modelov (napovedi), označujemo kot podatkovno vodeno organizacijo (Carillo, 2017). Pri tem je v ospredju podatkovna analitika, podatki pa so glavno gonilo takšne organizacije, na katerih temelji izdelava podatkovne

strategije in s tem povezani poslovni procesi ter poslovni modeli, predvsem pa odločanje. Takšna organizacija ima običajno razvito tudi določeno analitično miselnost in kulturo (Carillo, 2017). Pomemben del organizacije, temelječe na podatkih, predstavljajo tudi sistemi za podporo odločanju. Obstajajo različne vrste teh sistemov, in sicer sistemi, osnovani na modelih, dokumentih, podatkih ali znanju (ekspertni sistemi) (Power, Burstein in Sharda, 2011). Pri tem modelno osnovan odločitveni sistem temelji na podatkih in parametrih, ki jih posredujejo nosilci odločitev (odločevalci) (Power, 2000b). Na podlagi dostopnih podatkov in njihove manipulacije se zgradi optimizacijski ali simulacijski model. Takšni modeli ne vsebujejo nujno masovnih podatkov, medtem ko je pri odločitvenih modelih, osnovanih na podatkih, poudarek na uporabi velike baze podatkov, ki vključuje tako notranje kot tudi zunanje podatke organizacije (Power, 2000b). Poslovodstvo s pomočjo modela pridobi podatke ter na podlagi analize lažje identificira vzorce iz podatkov in dobi tudi podrobnejši vpogled v trende (Power, 2000a). Lahko povzamemo, da so podatki pomembno gonilo za ustvarjanje novega znanja in nam pomagajo sprejemati prave odločitve.

Čeprav je bilo v zadnjih letih veliko raziskav, ki naslavljajo tematiko podatkovno vodene organizacije, so se le-te v večji meri osredotočile na analitiko masovnih podatkov in njene zmogljivosti (Akter idr., 2016; Chen idr., 2015), vlogo podatkov pri inoviranju storitev in vpliv na spremembe v poslovnih modelih podjetij (Kühne in Böhmman, 2019; Trabucchi in Buganza, 2019), na načine, ki vplivajo na sprejetje podatkovno vodene kulture, in dejavnike, ki vplivajo na strateško odločanje po sprejetju analitike masovnih podatkov (Manohar, 2020; Rogers, 2020), ter izzive, s katerimi se organizacije srečujejo pri prehodu na podatkovno vodeno organizacijo (Berntsson Svensson in Taghavianfar, 2020). Ob tem je bilo zaznati manj raziskav, ki bi naslavljale podatkovno zrelost podjetij in pripadajoče modele podatkovne zrelosti, s katerimi ocenjujemo, v kateri fazi se podjetja nahajajo na poti podatkovno vodene organizacije in koliko imajo pravzaprav razvite sposobnosti ter orodja, s katerimi si pomagajo pri doseganju tega cilja. Ta problem je opaziti predvsem pri malih in srednje velikih podjetjih, ki večinoma nimajo jasno opredeljene podatkovne strategije in določene osebe, ki bi bila odgovorna za vodenje in pregled ter dosledno izvajanje le-te, predvsem pa je tudi manjše zavedanje pri uporabi podatkov kot strateškega vira v organizaciji. Zbiranje podatkov, njihovo upravljanje in urejanje s pomočjo operaterjev, ki skrbijo za ključne sisteme znotraj organizacije, pomaga pri

ohranjanju skladnosti podatkov in organizacijam omogoča, da postanejo v tej smeri bolj zrele (Rogers, 2020). Nedoslednost procesov lahko povzroči napačne podatke, slednje pa vpliva na sposobnost organizacij, da te napredujejo v smeri podatkovne zrelosti in postanejo podatkovno vodene.

### 3.1.1 Koncept podatkovno vodene organizacije

Veliko nejasnosti je moč opaziti že pri opredelitvi osnovnih pojmov, ki so povezani s konceptom podatkovno vodene organizacije, kot je na primer podatkovna znanost (islovar.org) oziroma podatkovne vede (<http://dis-slovarcek.ijs.si/>), ki predstavlja temelj takšne organizacije. **Podatkovna znanost** se nanaša na kombinacijo veščin, tehnik in orodij, ki jih organizacije uporabljajo za pridobivanje (ekstrakcijo) in manipulacijo podatkov in jim omogočajo prepoznavanje trendov ter oblikovanje predpostavk, ki vodijo do ključnih odločitev. Pri tem podatkovna znanost zajema tako majhen kot tudi velik nabor podatkov (velepodatke) (Dedge Parks, 2017). Drug primer pa predstavlja razvoj novih vlog in modelov, ki so se razvili zaradi neprestanega naraščanja in vse večjega pretoka podatkov, ki jih organizacije zajemajo. Čedalje pogosteje se omenjajo novi termini, kot so **podatkovni posrednik** (angl. data broker), **podatkovni skrbnik** (angl. data steward) in **podatkovni zaupnik** (angl. data trust), pojavlja pa se tudi pojem **digitalne podatkovne tržnice** (angl. data marketplace), ki se nanaša na vzpostavitev skupne točke za trgovanje s podatki med ponudniki in kupci oziroma prejemniki (v tem primeru majhnimi in srednje velikimi podjetji) v obliki spletne platforme (Stahl idr., 2016). Ponudnik podatkov posreduje podatke brezplačno ali proti plačilu lastniku podatkovne tržnice (podatkovnemu posredniku), ta pa naprej podatke proda končnemu uporabniku oziroma podjetju (Spiekermann, 2019). Podatkovni posrednik v tem primeru predstavlja vezni člen, ki med seboj povezuje ponudnike podatkov in končne uporabnike, kot so podjetja, in skrbi za nemoteno trgovanje podatkov. S tem sta zagotovljena neprestan pretok in izmenjava informacij ter podatkov, ki podjetju lahko prineseta nov vpogled v stranke in izboljšavo ponudbe vrednosti izdelkov ter storitev. Podatkovni skrbnik (angl. data steward) v tem primeru predstavlja odgovorno osebo za pridobivanje, shranjevanje in združevanje podatkov, ki jih posredujejo bodisi posamezniki ali podjetja, ter skrbi za njihovo sproščanje in posredovanje v uporabo (Rosenbaum, 2010). Zaokroženo celoto tvori proces upravljanja podatkov (angl. data governance), ki zajema konceptualizacijo in

izvedbo odgovornosti podatkovnega skrbnika z vzpostavitvijo politik za dostop, upravljanje in uporabo podatkov (Rosenbaum, 2010).

Med najvidnejše modele podatkovnega upravljanja (angl. data governance), ki smo jih zaznali pri pregledu literature, pa uvrščamo t. i. bazene za izmenjavo podatkov (angl. data sharing pools), podatkovne skupnosti (angl. data cooperatives) ter javne podatkovne sklade (angl. data sharing trusts). Tak primer je na primer prej omenjena uporaba podatkovne tržnice, zadnji primer pa predstavlja model podatkovne suverenosti (angl. personal data sovereignty). Vsak izmed modelov ima svoj pomen, kot ga opredeljujejo (Micheli idr., 2020).

Za poslovni ekosistem, kjer je vloga podatkov v ospredju, osnovni element komunikacije predstavljajo **podatkovne skupnosti**, ki so odgovorne za dodeljevanje dostopa in pravic do podatkov ter so povezane z ustvarjanjem bazenov za izmenjavo podatkov. V tem primeru podjetje posreduje podatke podatkovni skupnosti, kjer jim ta pomaga pri združevanju podatkov. Pri tem vsi deležniki podatke posredujejo prostovoljno, pri čemer ohranijo nadzor nad njimi ter tudi določajo način upravljanja in vrednotenja le-teh. Osrednjo vlogo ima podatkovni skrbnik, ki podatke zbere ter na podlagi opravljene analize posreduje vpogledne ponudnikom podatkov. Podatke lahko proda tudi naprej proti plačilu licence za uporabo podatkov, zato bazeni delujejo tudi kot licenčni modeli (Mattioli, 2017). Ob tem je **podatkovni bazen** namenjen predvsem združevanju različnih poslovnih deležnikov, kjer medsebojno sodelovanje le-teh pomaga pri identifikaciji in zapolnjevanju vrzeli v znanju, zmanjšajo se podvajanja podatkov, glavna prednost pa je omogočeno solastništvo podatkov, kar prispeva k centralizirani izmenjavi podatkov znotraj poslovnih ekosistemov. Bazeni za izmenjavo podatkov torej predstavljajo model za skupno združevanje podatkov, ki jih posredujejo ponudniki podatkov oziroma njihovi lastniki.

(Micheli idr., 2020) kot ključni mehanizem izpostavljajo opredelitev pogodbe, ki določa način izmenjave podatkov, njihove obdelave ter za kakšen namen se podatki izmenjujejo. Pri tem dodajajo še, da je to še posebej pomembno za organizacije, kjer je pomanjkanje strokovnega znanja ter pravne podpore za pridobivanje in izmenjavo podatkov, kamor bi lahko prištevali tudi majhna in srednje velika podjetja. **Model podatkovne suverenosti** pa se nanaša na upravljanje zasebnosti in prenosljivosti


podatkov, katere cilj je zagotavljanje čim večjega nadzora nad podatki, ki jih posredujejo lastniki podatkov, v tem primeru podjetja.

### 3.1.2 Stanje digitalne razvitosti držav

V literaturi je opaziti, da se za nadaljnje širjenje in hiter razvoj digitalne preobrazbe kot gonilo le-te kot glavni strateški vir kažejo podatki, ki s pomočjo podatkovne analitike, identifikacije kazalnikov in trendov vodijo k sprejemanju bolj natančnih odločitev, obenem pa nudijo podlago pri razvoju novih izdelkov in storitev ter s tem vplivajo na spreminjanje poslovnih modelov podjetij kot rezultat le-te. Čeprav je proces digitalne preobrazbe spodbudila tudi pandemija COVID-19, ki je od podjetij zahtevala dodatne prilagoditve predvsem v načinu dela, pa podjetja še vedno razmeroma počasi napredujejo pri dvigu stopnje digitalne intenzitete. Digitalna intenziteta se v tem primeru nanaša na stopnjo uporabe digitalnih tehnologij. Večja, kot je stopnja njihove uporabe, večja je stopnja digitalne intenzitete. Slika 3 prikazuje porazdeljenost doseganja digitalne intenzitete 27 evropskih držav v letu 2020, s podrobnejšo primerjavo med velikimi ter majhnimi in srednjimi podjetji. Podatki kažejo, da še vedno prevladujejo večja podjetja, medtem ko majhna in srednja podjetja precej zaostajajo. Pri večjih podjetjih prevladujejo predvsem države severne Evrope (Finska, Danska, Norveška, Belgija in Švedska). Med državami, ki so pri tem uspešnejše, je tudi Slovenija, vendar se to kaže le v primeru večjih podjetij. Pri majhnih in srednjih podjetjih to stopnjo dosega le okrog 45 % podjetij ali manj.


Bratuz Ferik idr. (2020) postavljajo podatke v ospredje in jih vidijo kot predpogoj pri napredovanju digitalizacije. Pri tem poudarjajo predvsem nujnost obvladovanja notranjih in zunanjih podatkov, ki jih podjetje lahko izkoristi za razvoj novih izdelkov in storitev, ki bodo za končnega uporabnika tudi bolj prilagojene. Obenem trdijo, da se bo zaradi podatkov v realnem času ter ob spremljanju potreb na trgu dvignila stopnja inoviranja, kar bo pospešilo tudi prototipiranje. Z večjim naborom izdelkov in storitev lahko podjetja razširijo ponudbo vrednosti in dvignejo nivo konkurenčnosti na trgu, kar je še posebej pomembno za majhna in srednja podjetja. Čeprav so podatki vedno bolj v ospredju digitalne preobrazbe, pa trend izkoriščanja podatkov kot strateškega vira med majhnimi in srednjimi podjetji napreduje razmeroma počasi.

Slika 4 prikazuje, v kolikšni meri so se majhna in srednja podjetja posluževala izvajanja analitike masovnih podatkov v letih 2016, 2018 in 2020. Pri tem so podjetja podatke zbirala iz različnih virov (telefoni, tablice, senzorji naprav, družbena omrežja). Podatki se razlikujejo glede na posamezne države in zajemajo 29 evropskih držav. Razvidno je, da se je trend pomembnosti podatkov in s tem izvajanje podatkovne analitike skoraj v polovici držav vsako leto povečeval (13 primerov). Od tega je največjo rast opaziti v šestih primerih (to so Danska, Malta, Nizozemska, Belgija, Irska in Združeno kraljestvo). Skoraj v enakem deležu, tj. v devetih primerih, je uporaba podatkovne analitike v letu 2020 upadla, medtem ko je v sedmih primerih prišlo do stagnacije oziroma mirovanja. Kljub temu pa majhna in srednja podjetja v povprečju podatke še vedno analizirajo le v manjši meri.



**Slika 3: Primerjava stopenj digitalne intenzitete evropskih držav med majhnimi, srednjimi in velikimi podjetji v letu 2020**

Vir: povzeto po (European Commission, b. d.)



**Slika 4: Uporaba analitike vele podatkov na nivoju držav med majhnimi in srednjimi podjetji v letih 2016, 2018 in 2020**

Vir: povzeto po (Eurostat, 2021)

Na podlagi prikazanih statistik sklepamo, da se večina majhnih in srednjih podjetij ne zaveda pomembnosti podatkov in tudi nima ustrezno opredeljenega pristopa k obvladovanju podatkov in njihovemu upravljanju, torej k temu problemu ne pristopa celovito. V ta namen so se razvili številni vprašalniki, modeli digitalne zrelosti in orodja, ki bi podjetjem pomagala pri opredelitvi tega problema, v zadnjih letih pa so se pričeli razvijati tudi modeli podatkovne zrelosti. Modeli podatkovne zrelosti služijo podjetjem za pridobivanje ocene stanja uporabe podatkov, njihovega izkoriščanja in upravljanja ter kot vodilo k ukrepom za napredovanje in nadziranje sprememb k bolj celovitemu podatkovnemu upravljanju.

V nadaljevanju predstavljamo nekaj zrelostnih modelov za oceno stopnje podatkovne zrelosti. Pri tem opredelimo tudi posamezne stopnje podatkovne zrelosti ter izpostavimo nekaj dejavnikov, s katerimi bi lahko opredelili podatkovno zrelost podjetij.

#### **4 Modeli podatkovne zrelosti**

Razvoj novih vlog in modelov upravljanja podatkov spodbuja organizacije zaradi vse večje digitalizacije k vpeljavi sprememb in prilagajanju poslovanja, katerega temelj predstavlja obvladovanje ter izkoriščanje podatkov. Jakus (2016) izpostavlja, da je še vedno preveč pozornosti usmerjene na zagotavljanje ustrezne infrastrukture ter uporabo orodij za dostop in obdelavo podatkov, pri čemer pa se izpušča pomen kakovosti podatkov. Razvoj digitalne preobrazbe in s tem napredovanje v smeri večje podatkovne zrelosti predstavlja največji problem za majhna in srednje velika podjetja. Poročilo OECD (OECD, 2021, str. 14) kot največje ovire navaja dostop do ustrezne infrastrukture, nizko medsebojno povezanost (interoperabilnost) sistemov podjetij, pomanjkanje podatkovne kulture ter zavedanja postavljanja digitalizacije v ospredje (angl. digital awareness). Ob tem izpostavlja tudi pomanjkanje s tem povezanih znanj. Dejavniki, ki vpliva na spodbuditev večje stopnje digitalne zrelosti, je tudi finančni vložek, potreben pri doseganju digitalne preobrazbe, predvsem pa je zaznati pomanjkanje jasno opredeljenih korakov za doseganje večje digitalne zrelosti. Modeli zrelosti se razvijajo že od osemdesetih let prejšnjega stoletja, ko je bil najprej razvit zrelostni model zmogljivosti (angl. Capability maturity model integration - CMMI), ki še danes predstavlja osnovo za nadaljnji razvoj današnjih digitalnih zrelostnih modelov (Koren, 2017). V literaturi se pojem digitalne zrelosti najpogosteje opredeljuje kot stanje, ki določa nabor

sprememb, ki jih je podjetje že doseglo na poti digitalne preobrazbe z operativnega vidika (spremembe izdelkov ali procesov) in vidika obvladovanja sprememb v podjetju (Chanas in Hess, 2016). Da bi se dvignila stopnja upravljanja podatkov in zagotovil celovit pregled nad podatki, ki jih podjetja zbirajo in analizirajo, so se v ta namen pričeli razvijati modeli podatkovne ali informacijske zrelosti.

Kljub razvoju tovrstnih modelov je med pregledom literature še vedno opaziti pomanjkanje modelov, ki bi se konkretno nanašali na majhna in srednje velika podjetja. Večje organizacije in svetovalna podjetja, kot so Deloitte, Oracle in Gartner, so v preteklosti razvijala predvsem modele digitalne zrelosti, ki opredeljujejo digitalno preobrazbo širše in manj v smeri podatkovne zrelosti. V zadnjih letih pa so se tudi ta podjetja pričela čedalje bolj usmerjati k razvoju modelov za oceno podatkovne zrelosti. Deloitte (Deloitte, 2019) je na primer za podjetja, ki delujejo na področju medijev in novinarstva, skupaj s podjetjem Google razvil okvir za razvoj podatkovnih temeljev (angl. Data Activation Framework) kot pomoč organizacijam pri doseganju večje podatkovne zrelosti. Model sledi trem korakom. Prvi se nanaša na vzpostavitev in določitev strategije, drugi korak zadeva razvoj organizacijske kulture, znanj in tehnologij za pridobivanje in upravljanje podatkov. Tretji korak pa se osredotoča na pridobivanje vrednosti iz podatkov. Oracle (Hornick, 2020) se je pri razvoju modela osredotočil na 10 dimenzij, kjer je vsaka izmed njih merjena s petimi nivoji podatkovne zrelosti. Po predlaganem modelu ima popolnoma podatkovno vodena organizacija podatke opredeljene kot glavni strateški vir, določeno odgovorno osebo za vodenje podatkovne strategije in izvajanje le-te (angl. Chief Data Officer), standardizirana orodja in opredeljeno metodologijo za izvedbo projektov, kjer so podlaga podatki, urejeno sledenje dostopa do podatkov ter sistematično upravljanje le-teh ob ustrezni infrastrukturi. Gartner (Gartner, 2018) pa je poleg podatkov pri razvoju modela upošteval tudi podatkovno analitiko. Ob tem je podanih tudi precej vodil in usmeritev k opredelitvi podatkovne zrelosti v podjetju, kjer pa so te v večini precej generične in zato morda manj primerne za majhna in srednja podjetja, predvsem pa so manj usmerjene v jasno opredelitev merjenja podatkovne zrelosti organizacij. V tabeli 1 so s pripadajočimi dimenzijami podani pravkar opisani primeri modelov podatkovne zrelosti. V podanih primerih je zaznati, da se modeli precej nanašajo na reševanje strukturiranega dela podatkov v podjetjih, medtem ko ni jasne opredelitve, ali so ti primerni za vključitev tudi nestrukturiranih podatkov. Za uspešno napredovanje podatkovne zrelosti bi se morale organizacije najprej osredotočiti na pregled



tehnologij, virov in orodij ter ob uporabi teh identificirati, katere izmed podatkov shraniti, se jim podrobneje posvetiti ali pa zaradi vsebine niso relevantni in se jih zato ne upošteva (Al-Sai idr., 2019).

**Tabela 1: Modeli podatkovne zrelosti organizacij**

Avtor	Okvir (model)	Elementi ocenjevanja (dimenzije)
(Deloitte, 2019)	Okvir za razvoj podatkovnih temeljev	4 dimenzije: Organizacijska kultura, znanja (kompetence), tehnologija, podatki
(Hornick, 2020)	Model zrelosti podatkovne znanosti	10 dimenzij: Strategija, vloge, sodelovanje, metodologija, podatkovno zavedanje, dostop do podatkov, elastičnost (skalabilnost), upravljanje virov, orodja in uvedba
(Gartner, 2018)	Model podatkovne zrelosti in analitike	*5 stopenj podatkovne zrelosti: Osnovna stopnja, stopnja priložnosti, stopnja sistematičnosti, stopnja diferenciacije in stopnja transformacije

\* Gartnerjev model nima podanih dimenzij, zato so v tabeli podane posamezne stopnje

V znanstveni literaturi še vedno prevladujejo modeli, ki so vezani predvsem na velika podjetja in usmerjeni na področje masovnih podatkov (Al-Sai idr., 2019; Comuzzi in Patel, 2018). Obstoječi modeli imajo na tem področju nizko stopnjo dokumentacije, potrebna je večja osredotočenost tudi na zasebnost in varnost podatkov, predvsem pa je pomanjkanje opravljene validacije modelov. Ob tem so se raziskave v zadnjih letih pričele osredotočati tudi na majhna in srednje velika podjetja z razvojem modelov podatkovne zrelosti, ki so za njih bolj primerni. Weber idr. (2017) so razvili zrelostni model, namenjen proizvodnim podjetjem, katerih delovanje temelji na podatkih. Za doseganje podatkovno vodene proizvodnje morajo podjetja upoštevati naslednjih 6 stopenj. Na začetku je treba zagotoviti povezanost sistemov in orodij z informacijsko tehnologijo. Sledi povezava podatkov s sistemi in vzpostavitev podatkovne analitike. V tretji stopnji mora podjetje vključiti podatke iz ostalih virov (prodaja, logistika, družbeni mediji), v četrti stopnji sledi izmenjava povezanih podatkov. Po vzpostavitvi združenih podatkov in zagotavljeni medsebojni komunikaciji sledi vzpostavitev digitalnega dvojnika (angl. digital twin) in s tem enotnega podatkovnega modela, ki omogoča preslikavo realnih proizvodnih sistemov. Zadnja stopnja pa se nanaša na vzpostavitev koncepta pametne tovarne, kjer sistemi podjetja ob zagotavljanju podatkov delujejo avtonomno. Med pregledom literature smo opazili tudi pojavljanje novih modelov, kot je okvir

zrelosti, vezan na upravljanje podatkov v oblaku, avtorjev (Guangming idr., 2017). Predlagani okvir v tem primeru podatkovno zrelost ocenjuje skozi 6 različnih dimenzij (podatkovna strategija, podatkovno upravljanje, kakovost podatkov, podatkovne operacije, podatkovna arhitektura ter varnost in zasebnost podatkov). V obeh primerih pogrešamo bolj jasno opredelitev dejavnikov (kriterijev), ki bi majhnim in srednjim podjetjem lahko zagotovili večjo samostojnost pri oceni podatkovne zrelosti in opredelitev potrebnih korakov za doseganje le-te. Poleg tega se v literaturi pojavljajo tudi modeli, ki bi majhnim podjetjem lahko pomagali določiti podatkovnega skrbnika (Plotkin, 2014), srednje velikim pa opredeliti, v kateri stopnji zrelosti imajo to vlogo že razvito. Drugi, (Parra idr., 2019) so se osredotočili na oceno zrelosti informacij in z modelom za oceno stopnje informacijske zrelosti preučili tri majhna in srednje velika podjetja skozi pet različnih dimenzij (razpoložljivost podatkov, kakovost podatkov, analiza in vpogled v podatke, uporaba informacij in odločanje). Ob tem izpostavljajo, da ima večina podjetij še vedno težave pri identifikaciji ključnih informacij, zaznati pa je tudi pomanjkanje izkoriščanja uporabe podatkovne analitike, kjer lahko le-ta prispeva k večjemu razumevanju identificiranih podatkov in informacij. V tabeli 2 je poleg predstavljenih podanih še nekaj modelov podatkovne zrelosti, s podanimi dimenzijami in ciljno skupino, ki jo ti naslavljajo.

**Tabela 2: Modeli podatkovne zrelosti organizacij**

Avtor	Okvir (model)	Ciljna skupina	Elementi ocenjevanja (dimenzije)
(Weber idr., 2017)	Model zrelosti za podatkovno vodeno proizvodnjo	Proizvodna podjetja	*6 zrelostnih stopenj: 0 – neobstoječa integracija z IT 1 – povezava sistemov in podatkov (podatkovna analitika) 2 – integracija ostalih podatkovnih virov (življenjski cikel podatkov) 3 – izmenjava povezanih podatkov

Avtor	Okvir (model)	Ciljna skupina	Elementi ocenjevanja (dimenzije)
			4- vzpostavitev digitalnega dvojnika 5 – avtonomno delovanje in komunikacija sistemov
(Guangming idr., 2017)	Model zrelosti za upravljanje podatkov v oblaku	Majhna in srednja podjetja	6 dimenzij: podatkovna strategija; podatkovno upravljanje; kakovost podatkov; podatkovne operacije; podatkovna arhitektura; varnost in zasebnost podatkov;
(Plotkin, 2014)	Model ocene zrelosti podatkovnega skrbnika	Srednja in večja podjetja (potencialno tudi majhna)	4 dimenzije: organizacijsko zavedanje; podatkovne vloge in strukture; podatkovni standardi, politike in procesi; ustvarjanje vrednosti iz podatkov
(Sternkopf in Mueller, 2018)	Model zrelosti za oceno podatkovne pismenosti	Nevladne organizacije, majhna, srednja in velika podjetja	3 glavne dimenzije in 8 poddimenzij: podatkovna kultura; podatkovna etika in varnost; *opredelitev vprašanja (iskanje, pridobivanje, preverjanje, čiščenje, analiziranje, komunikacija, ocenjevanje in interpretacija)
(Parra idr., 2019)	Model za oceno podatkovne zrelosti	Majhna in srednja podjetja	5 dimenzij: razpoložljivost podatkov, kakovost podatkov, analiza in

Avtor	Okvir (model)	Ciljna skupina	Elementi ocenjevanja (dimenzije)
			vpogled v podatke, uporaba informacij in odločanje
(Loshin, 2011)	Model zrelosti za oceno kakovosti podatkov	Majhna, srednja in velika podjetja	8 dimenzij: ocena pričakovane podatkovne kakovosti, mere podatkovnih dimenzij, podatkovne politike, protokoli kakovosti podatkov, upravljanje podatkov, podatkovni standardi, tehnologija, poročanje o uspešnosti
(Cech idr., 2018)	Model zrelosti za oceno obvladovanja	Majhna, srednja in velika podjetja	* 5 stopenj podatkovne zrelosti: začetna stopnja, stopnja definiranosti, stopnja integracije, stopnja optimizacije, stopnja napredovanja
(European Commission, 2018; Wilkinson idr., 2019)	Metoda FAIR za merjenje zrelosti nabora podatkov	Majhna, srednja in velika podjetja	4 dimenzije iskanje podatkov, podatkovna dostopnost, interoperabilnost, ponovna uporabnost

\* Modela avtorjev (Weber idr., 2017) in (Cech idr., 2018) nimata podanih dimenzij, zato so v tabeli podane posamezne stopnje podatkovne zrelosti

Da bi organizacije lahko ugotovile, ali so podatki, ki jih zajemajo, dejansko pomembni z vidika ustvarjanja dodane vrednosti, je pomembno določiti obseg podatkov, njihovo kakovost in identificirati njihovo dostopnost (Farah, 2017). V ta namen se je razvila metoda FAIR (angl. Findability, Accessibility, Interoperability, Reusability), ki se uporablja za merjenje zrelosti nabora podatkov (angl. dataset), projektov in podatkovne infrastrukture (European Commission, 2018; Wilkinson

idr., 2019). Organizacijam pomaga pri določanju, kako dobro upravlja s podatki, ki jih ima na voljo, ali s podatki, ki jih ustvarja sama. Prvi element, tj. iskanje podatkov, opredeljuje stopnjo urejenosti organiziranosti popisa podatkov, ki jih organizacija ustvarja ali upravlja. Dostopnost do podatkov opredeljuje, koliko je organizacija učinkovita pri pridobivanju svojih podatkov. Interoperabilnost teži k ohranitvi natančne oblike in pomenu izmenjanih podatkov. S tem se preveri, ali ima organizacija urejen enoten podatkovni format za izmenjavo podatkov. Organizacija tako lažje doseže tudi večjo medsebojno povezanost poslovnih sistemov. Zadnji element, tj. podatkovna uporabnost, pa opredeljuje, ali so izdani podatki jasni in zato uporabni tudi za naprej.

Iz tabele 2 je razvidno, da so se modeli za oceno podatkovne zrelosti za majhna in srednja podjetja pričeli šele dobro razvijati. Zbrane modele vidimo kot dobro osnovo za izdelavo novega modela podatkovne zrelosti, ki bi povezoval omenjene dimenzije v celoto in tako majhnim in srednjim podjetjem ponudil enoten model za opredelitev trenutnega stanja in opredelitev jasne podatkovne strategije. Predvsem je potrebno najprej narediti pregled nad podatki, ki jih podjetja zbirajo, in narediti oceno kakovosti podatkov. Model, kot ga je predlagal (Loshin, 2011), omogoča oceno stanja podatkovne kakovosti s pregledom stanja podatkov (pregled dimenzij in veljavnosti podatkov) ter opredelitev strategije. S tem modelom se oceni tudi, ali so v podjetju tudi že vzpostavljeni standardi podatkovne kakovosti. Drugi (Hunke idr., 2017) pa so se usmerili na področje poslovnih modelov, kjer so razvili procesni model, ki organizacijam pomaga pri oblikovanju poslovnega modela, ki temelji na podatkih.

#### 4.1 Opredelitev stopenj podatkovne zrelosti

Večina avtorjev (Cech idr., 2018; Loshin, 2011; Spruit in Pietzka, 2015) pri modelih za ocenjevanje podatkovne zrelosti sledi petim osnovnim zrelostnim stopnjam, ki izhajajo iz osnovnega zrelostnega modela zmogljivosti CMMI (angl. Capability Maturity Model Integration):

– Začetna stopnja (angl. initial level)

Na tej stopnji podjetje podatke izkorišča le v manjši meri, ni vzpostavljenega sistema upravljanja podatkov, prav tako je manjše zavedanje in izkoriščanje podatkovnih virov, ki jih ima podjetje na voljo. Podjetje na tej stopnji nima vzpostavljenega sledenja podatkov, podatki so precej razpršeni, zaradi česar je oteženo tudi zagotavljanje primerne kakovosti le-teh. Poleg tega je nizka stopnja uporabe tehnologij in orodij za izvajanje analize podatkov. Ni določene podatkovne strategije in osebe, ki bi vodila celoten proces le-te.

– Stopnja ponavljanja (angl. repeatable level)

Stopnja zavedanja je v tej fazi že nekoliko večja in s tem večje zavedanje o uporabi informacij in podatkov. Večji je tudi pretok podatkov in deljenja informacij. Vzpostavljen je tudi osnovni proces upravljanja podatkov in informacij, pri čemer se določeni pristopi upravljanja podatkov pričenjajo ponavljati in so izraženi kot primeri dobre prakse. Definiran je torej sistematičen pristop k upravljanju podatkov in informacij, spodbujeno je povezovanje oddelkov. Kljub temu so procesi dokumentirani le deloma, na posameznih oddelkih ni enotnih dokumentacijskih praks in zagotovljenega celovitega upravljanja podatkov.

– Stopnja definiranosti (angl. defined level)

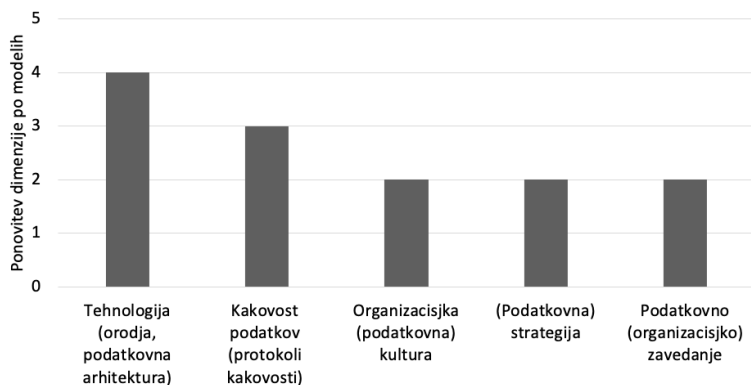
Na tej stopnji so podatki in podatkovni viri jasno določeni in zbrani v skupek informacij (podatkovni katalog). Določi se tudi skupina zaposlenih, ki skrbi za kakovost podatkov z vzpostavitvijo politik in pravil za upravljanje podatkov. Podatki morajo biti v tej stopnji že urejeni in zagotavljati določeno mero uporabnosti. Prav tako se vzpostavijo procesi in storitve za zagotavljanje točnosti informacij ter določijo sistemi za upravljanje teh. Podatki se pripravijo tudi za namen shranjevanja v podatkovna skladišča. (Cech idr., 2018) izpostavljajo še stopnjo integracije, kjer se za shranjevanje vzpostavijo podatkovna skladišča. Na tej stopnji se uporabljajo tudi že podatkovna analitika, orodja in vizualizacije, ki odločevalcem v podjetju olajšajo interpretacijo podatkov, počasi se razvija tudi vzpostavitev podatkovne kulture, kjer so odločitve v podjetju podkrepjene na podlagi točnih podatkov.

- Stopnja optimizacije (angl. optimized level)

Tu so kompetence zaposlenih, ki so vezane na upravljanje podatkov in uporabo statističnih orodij, že razvite in se le nadgrajujejo, prav tako tudi uporaba orodij. Na tej stopnji se upravljanje podatkov le optimizira. Za izkoriščanje vrednosti podatkov se uporabljajo tudi orodja za izdelavo napovednih modelov (napovedi), spodbuja pa se tudi vključitev oseb, kot sta podatkovni znanstvenik, ki v podjetju skrbi in pomaga pri analizi podatkov, in podatkovni skrbnik, ki skrbi za celotno izvajanje podatkovne strategije. Nekateri, kot so (Cech idr., 2018) dodajajo še stopnjo napredovanja (angl. advanced level), kjer podjetje s podatki nadalje eksperimentira v povezavi z akademskim okoljem, in sicer z namenom oblikovanja primernih podatkovnih politik.

#### 4.2 Prevladujoče dimenzije modelov podatkovne zrelosti

Kljub raznolikosti zbranih modelov v tabeli 2 je razvidno, da med merami za določanje in ocenjevanje podatkovne zrelosti organizacij še vedno prevladuje tehnologija in uporaba orodij (slika 5). Druga najpomembnejša dimenzija je kakovost podatkov. Nekoliko manj je poudarka na organizacijski oziroma podatkovni kulturi, podatkovni strategiji in oceni podatkovnega zavedanja, torej v kakšni meri organizacija podatke obravnava kot strateški vir. Na osi X so prikazane posamezne dimenzije za določanje ocene podatkovne zrelosti, os Y pa označuje ponovitev posamezne dimenzije in s tem njeno pomembnost pri ocenjevanju zrelosti. Zanimivo je, da se med modeli kot manj pomembna dimenzija za določanje podatkovne zrelosti kaže odločanje, kjer podatki predstavljajo poglobitni del. Prav tako se zdi, da so avtorji modelov dali manj teže opredelitvi vlog in struktur, ki so potrebne za uspešno doseganje podatkovno vodene organizacije.



Slika 5: Pomembnost posameznih dimenzij pri oceni podatkovne zrelosti organizacij

## 5 Diskusija in zaključki

Digitalna preobrazba je organizacije spodbudila k večji uporabi digitalnih tehnologij in orodij, povečala se je količina podatkov ter tudi potreba po večji povezljivosti sistemov (in podatkov). S tem pa vse bolj raste pomembnost vloge podatkov kot glavnega strateškega vira za komunikacijo in razvoj novih izdelkov, storitev ter poslovnih modelov. Čeprav se podatki kažejo kot vedno bolj pomemben vir, pa je ob pregledu literature zaznati, da se je področje podatkov šele pričelo dobro razvijati, kar nakazuje tudi nabor modelov, s katerimi lahko ocenimo podatkovno zrelost organizacij. Ti so v večji meri še vedno usmerjeni na večja podjetja, ki so od majhnih in srednjih bolj digitalno razvita, kar kažejo tudi podatki statističnega urada Eurostat (sliki 3 in 4). V literaturi je zaznati, da se ob vseprisotni digitalizaciji in povečani količini podatkov vedno večjo pozornost usmerja v pojav novih vlog (npr. podatkovni skrbnik, podatkovni posrednik, podatkovna tržnica) in modelov upravljanja podatkov (podatkovni bazen, podatkovne skupnosti). Zaznati je pomanjkanje modelov podatkovne zrelosti, ki bi konkretnije majhnim in srednje velikim podjetjem omogočila možnost ocene podatkovne zrelosti. Tovrstni modeli nudijo oceno zrelosti (v določenem trenutku) ter pregled po posameznih področjih ocenjevanja, na primer koliko podatkov zbirajo, ali imajo urejeno ustrezno podatkovno strategijo in določeno osebo (podatkovnega skrbnika) za dosledno izvajanje le-te, koliko svoje podatke vključujejo v odločitve in koliko so pravzaprav podatkovno pismeni. Pri tem velik dejavnik predstavlja podatkovna kultura, pri kateri mora biti največji spodbujevalec sprememb vodstvo podjetja.



Mikro, majhna in srednja podjetja bi morala na tem področju najprej dvigniti stopnjo zavedanja o pomembnosti podatkov ter razumevanja, kakšno vrednost le-ti nosijo. Na podlagi tega se v podjetju začne graditi podatkovno kulturo in strategijo. Študije kažejo, da na to vplivajo jasno določene vloge podatkovnih skrbnikov. Podjetje mora imeti jasen pregled nad podatki, ki jih zbira in z njimi upravlja, ter jasno določeno, kdo je odgovoren za njihovo kakovost. Za lažje upravljanje in izmenjavo podatkov so se razvili procesni modeli podatkovnega upravljanja, ki bi tudi majhnim in srednjim podjetjem olajšali obvladovanje podatkov in sodelovanje z drugimi deležniki poslovnega ekosistema. Ob tem se pojavljajo nove oblike poslovnih modelov, kot je na primer podatkovna tržnica, ki bi majhnim in srednjim podjetjem ponudila enotno točko za dostop do podatkov večjih podjetij, in sicer ob plačilu licence za njihovo uporabo. Velika podjetja bi manjšim lahko na ta način ponudila podatke potrošniških nakupovalnih navad, kot je na primer Amazon. S tem bi manjša podjetja prilagodila izdelke in storitve, ki bi bili za stranke bolj personalizirani. Drug primer so lahko podatki o delovanju proizvodne linije, zajeti s pomočjo kamere in z uporabo strojnega vida. Podjetje bi iz zbranih podatkov lahko izdelalo napovedni model za napovedovanje okvar proizvodne linije. Da so podatki izjemnega pomena, kaže tudi to, da je Evropska unija nedavno sprejela podatkovno strategijo (European strategy for data), kjer podatke izpostavlja kot glavni strateški vir za nadaljnji razvoj in inoviranje poslovnih modelov podjetij. Predvsem se ta nanaša na odprte podatke, ki so namenjeni ponovni uporabi in izmenjavi. Sicer se s pravnega vidika na podatke v večini nanašajo pravni akti s področja varovanja osebnih podatkov, kot je splošna uredba o varovanju osebnih podatkov (angl. GDPR – General Data Protection Regulation) (European Commission, 2016), ki zagotavlja varovanje pravic posameznika (varovanje osebnih podatkov, preprečuje manipuliranje z osebnimi podatki in anonimizacijo osebnih podatkov).

V prispevku smo obravnavali problem upravljanja podatkov v malih in srednje velikih podjetjih z vidika zrelostnih modelov. Zrelostni modeli so zelo razširjeni na različnih področjih, srečamo jih tako v teoriji kot tudi implementacije v praksi. Na problem upravljanja podatkov pa lahko gledamo tudi z vidika procesa upravljanja podatkov, ki je neločljiv del širšega procesa upravljanja informatike v organizaciji. Nadalje lahko problem analiziramo tudi z vidika sprejetosti tehnologij, saj so podatki osnovna vhodna surovina v informacijski sistem in so s tem neločljivo povezani s tehnologijo, ki jo pri tem uporabljamo. Za razvoj celovitega modela, ki bo majhnim in srednje velikim podjetjem pomagal pri prehodu v digitalno oziroma podatkovno

ekonomijo, bo potrebno preučiti in vključiti tudi druge vidike. Zavedati se moramo, da se za razliko od velikih podjetij soočajo mikro, mala in srednja podjetja s pomanjkanjem finančnih in kadrovskih virov ter pomanjkanjem ustreznih kompetenc, ki bi jim omogočile celovito obvladovanje in upravljanje podatkov. Celovit model za oceno stopnje podatkovne zrelosti bi tako majhnim in srednjim podjetjem omogočil pregled trenutnega stanja zrelosti, identifikacijo tehnologij, orodij in kompetenc, ki jih potrebujejo. Vrednost tovrstnih modelov pa ni le v oceni trenutnega stanja, pač pa imajo tudi izobraževalni učinek, saj uporabnike spoznajo s posameznimi elementi, ki so pomembni pri vzpostavljanju podatkovne zrelosti, omogočajo pa tudi spremljanje napredka.

### Zahvala

Raziskavo finančno podpira ARRS v okviru programa P5-018 »Sistemi za podporo odločanju v digitalnem poslovanju« in programa usposabljanja za mladega raziskovalca

### Literatura

- Abbasi, 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](https://aisel.aisnet.org/jais/big_data_info_systems.pdf)
- Akter, S., Fosso Wamba, S., Gunasekaran, A., Dubey, R., & Childe, S. J. (2016). How to improve firm performance using big data analytics capability and business strategy alignment? *International Journal of Production Economics*, 182, 113–131. <https://doi.org/10.1016/j.ijpe.2016.08.018>
- Al-Sai, Z. A., Abdullah, R., & Husin, M. H. (2019). A Review on Big Data Maturity Models. *IEEE Jordan International Joint Conference on Electrical Engineering and Information Technology (JEIT)*, 156–161. <https://ieeexplore-ieee.org.ezproxy.lib.ukm.si/stamp/stamp.jsp?tp=&arnumber=8717398&tag=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/0fc1/5b775475b97c5e29d1422af5df6afef8e446.pdf>
- Baker, B. (1995). The role of feedback in assessing information systems planning effectiveness. *Journal of Strategic Information Systems*, 4(1), 61–80. [https://doi.org/10.1016/0963-8687\(95\)80015-1](https://doi.org/10.1016/0963-8687(95)80015-1)
- 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](https://doi.org/10.1007/978-3-030-50316-1_1)
- big-data-value.eu. (b. d.). *Homepage - Big Data Value*. Pridobljeno 20. april 2021., od <https://www.big-data-value.eu/>
- Bratuž Ferik, B., Celebič, T., Fajič, L., Golob Suštersič, T., Hribernik, M., Kajzer, A., Ivas, K., Kovač, M., Kmet Zupancič, R., Kušar, J., Lušina, U., Palčič, I., Povšnar, J., Sodja, U., Stare, M., Todorović Jemec, N., Vidrih, A., Wostner, P., & Korošec, V. (2020). *Poročilo o produktivnosti 2020*. [https://www.umar.gov.si/fileadmin/user\\_upload/publikacije/Porocilo\\_o\\_productivnosti/2](https://www.umar.gov.si/fileadmin/user_upload/publikacije/Porocilo_o_productivnosti/2)

- 020/slovenski/PoP\_2020\_splet.pdf
- Brynjolfsson, E., Hitt, L., & Kim, H. (2011). *Strength in numbers: How does data-driven decision-making affect firm performance?* <https://doi.org/10.2139/ssrn.1819486>
- 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>
- Cech, T. G., Spaulding, T. J., & Cazier, J. A. (2018). Data competence maturity: developing data-driven decision making. *Journal of Research in Innovative Teaching & Learning*, 11(2), 139–158. <https://doi.org/10.1108/JRIT-03-2018-0007>
- 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](https://www.wim.bwl.uni-muenchen.de/download/epub/mreport_2016_2.pdf)
- Chen, D. Q., Preston, D. S., & Swink, M. (2015). How the Use of Big Data Analytics Affects Value Creation in Supply Chain Management. *Journal of Management Information Systems*, 32(4), 4–39. <https://doi.org/10.1080/07421222.2015.1138364>
- 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>
- Comuzzi, M., & Patel, A. (2018). How organisations leverage Big Data: a maturity model. *Industrial Management & Data Systems*, 116(8), 1468–1492. <https://doi.org/10.1108/IMDS-12-2015-0495>
- Dedge Parks, D. M. (2017). *Defining Data Science and Data Scientist* [University of South Florida]. <https://search-proquest-com.ezproxy.lib.ukm.si/pqdtglobal/docview/1983449433/fulltextPDF/12D1251AE3514693PQ/1?accountid=28931>
- Deloitte. (2019). *Digital transformation through data: A guide for news and media companies to drive value with data.* <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/technology-media-telecommunications/us-digital-transformation-through-data-for-news.pdf>
- edincubator.eu. (b. d.). *EDI - European Data Incubator | EDI - European Data Incubator*. Pridobljeno 20. april 2021., od <https://edincubator.eu/>
- European Commission. (b. d.). *Enterprises with High levels of Digital Intensity*. [https://digital-agenda-data.eu/charts/analyse-one-indicator-and-compare-breakdowns#chart=%7B%22indicator-group%22:%22business%22,%22indicator%22:%22e\\_di\\_hivhi%22,%22breakdown-group%22:%22bytesize%22,%22unit-measure%22:%22pc\\_cnt%22,%22time-period%22:%22](https://digital-agenda-data.eu/charts/analyse-one-indicator-and-compare-breakdowns#chart=%7B%22indicator-group%22:%22business%22,%22indicator%22:%22e_di_hivhi%22,%22breakdown-group%22:%22bytesize%22,%22unit-measure%22:%22pc_cnt%22,%22time-period%22:%22)
- European Commission. (2016, april 27). *REGULATION (EU) 2016/679*. <https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=CELEX:32016R0679&from=EN>
- European Commission. (2018). *Measuring maturity of data*. [https://ec.europa.eu/isa2/actions/measuring-maturity-data\\_en](https://ec.europa.eu/isa2/actions/measuring-maturity-data_en)
- European Commission. (2020). *COM(2020)66 - A European strategy for data*. <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:52020DC0066&from=EN>
- Eurostat. (2021). *Big data analysis*. <http://appsso.eurostat.ec.europa.eu/nui/submitViewTableAction.do>
- 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)
- Fruhirth, M., Breiffuss, G., & Pammer-Schindler, V. (2020). THE DATA PRODUCT CANVAS A VISUAL COLLABORATIVE TOOL FOR DESIGNING DATA-DRIVEN BUSINESS MODELS. *33rd Bled eConference – Enabling Technology for a Sustainable Society*, 515–528. <https://doi.org/https://doi.org/10.18690/978-961-286-362-3.35>
- 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>

- Gašperlin, B., Pucihar, A., & Kljajić Borštnar, M. (2021). Influencing Factors of Digital Transformation in SMEs – Literature Review. V P. Šprajc, A. Žnidaršič, D. Maletič, D. Tomič, N. Petrović, O. Arsenijević, V. Uli, & Y. Ziegler (Ur.), *40th International Conference on Organizational Science Development: Values, Competencies and Changes in Organizations* (str. 231–244). University of Maribor, University Press. <https://doi.org/10.18690/978-961-286-442-2.17>
- 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>
- Hartmann, P. M., Zaki, M., Feldmann, N., & Neely, A. (2016). Capturing value from big data—a taxonomy of data-driven business models used by start-up firms. *International Journal of Operations & Production Management*, *36*(10), 1382–1406. <https://doi.org/10.1108/IJOPM-02-2014-0098>
- Hornick, M. (2020). *A Data Science Maturity Model for Enterprise Assessment*. <https://www.oracle.com/a/devo/docs/data-science-maturity-model.pdf>
- Hunke, F., Seebacher, S., Schuritz, R., & Illi, A. (2017). Towards a process model for data-driven business model innovation. *Proceedings - 2017 IEEE 19th Conference on Business Informatics, CBI 2017*, *1*, 150–157. <https://doi.org/10.1109/CBI.2017.43>
- I-BiDaaS. (b. d.). *Home | i-BiDaaS*. Pridobljeno 20. april 2021., od <https://www.ibidaas.eu/>
- IDC. (2020). *RETHINK DATA: Put More of Your Business Data to Work - From Edge to Cloud*. [https://www.seagate.com/files/www-content/our-story/rethink-data/files/Rethink\\_Data\\_Report\\_2020.pdf](https://www.seagate.com/files/www-content/our-story/rethink-data/files/Rethink_Data_Report_2020.pdf)
- Jakus, D. (2016). *ZAGOTAVLJANJE KAKOVOSTI PODATKOV V SISTEMIH POSLOVNE INTELIGENCE NA PRIMERU ŠTUDENTSKEGA INFORMACIJSKEGA SISTEMA EKONOMSKE FAKULTETE V LJUBLJANI* [Ekonomski fakulteta]. <http://www.cek.ef.uni-lj.si/magister/jakus4990.pdf>
- Kljajić Borštnar, M., Kljajić, M., Škraba, A., Kofjač, D., & Rajkovič, V. (2011). The relevance of facilitation in group decision making supported by a simulation model. *System Dynamics Review*, *27*(3), 270–293. <https://doi.org/10.1002/sdr.460>
- 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>
- Koren, T. (2017). *Ocena stopnje digitalne zrelosti v slovenskih podjetjih* [Univerza v Ljubljani, Ekonomska fakulteta]. <http://www.cek.ef.uni-lj.si/magister/koren2658-B.pdf>
- Kühne, B., & Böhm, T. (2019). Data-driven business models - Building the bridge between data and value. *27th European Conference on Information Systems: Information Systems for a Sharing Society, ECIS*. [https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1166&context=ecis2019\\_rp](https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1166&context=ecis2019_rp)
- Loebbecke, C., & Picot, A. (2015). Reflections on societal and business model transformation arising from digitization and big data analytics: A research agenda. *Journal of Strategic Information Systems*, *24*(3), 149–157. <https://doi.org/10.1016/j.jsis.2015.08.002>
- 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=i nfo:qMsybD7zSZUJ:scholar.google.com&ots=0SVyX2ZfGX&sig=Hux9Ymbl0emIu8MJTC qmY3CihU&redir\\_esc=y#v=onepage&q&f=false](https://books.google.si/books?hl=en&lr=&id=B3zd4GCAWeYC&oi=fnd&pg=PR3&dq=i nfo:qMsybD7zSZUJ:scholar.google.com&ots=0SVyX2ZfGX&sig=Hux9Ymbl0emIu8MJTC qmY3CihU&redir_esc=y#v=onepage&q&f=false)
- Manohar, P. (2020). *Impact of Adopting Big Data Analytics on Strategic Decisions: A Delphi Study Using the Technology-Organization Environment (TOE) Framework* [Capella University]. <https://search-proquest-com.ezproxy.lib.ukm.si/pqdtglobal/docview/2456453062/C244AA71F724A4EPQ/10?accountid=28931>
- 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>
- Marolt, M., Lenart, G., Borštnar, M. K., Vidmar, D., & Pucihar, A. (2018). SMEs perspective on business model innovation. *31st Bled eConference: Digital Transformation: Meeting the Challenges*,

- BLLED 2018, 577–592. <https://doi.org/10.18690/978-961-286-170-4.40>
- Maroufkhani, P., Tseng, M. L., Iranmanesh, M., Ismail, W. K. W., & Khalid, H. (2020). Big data analytics adoption: Determinants and performances among small to medium-sized enterprises. *International Journal of Information Management*, 54, 1–15. <https://doi.org/10.1016/j.ijinfomgt.2020.102190>
- Mattioli, M. (2017). The Data-Pooling Problem. *Berkeley Technology Law Journal*, 32(1), 179–236. <https://doi.org/10.15779/Z38R785P10>
- McAfee, A., & Brynjolfsson, E. (2012). Big Data: The Management Revolution. *Harvard Business Review*. <https://hbr.org/2012/10/big-data-the-management-revolution>
- McKinsey. (2020). *How six companies are using technology and data to transform themselves* | McKinsey. <https://www.mckinsey.com/business-functions/mckinsey-digital/our-insights/how-six-companies-are-using-technology-and-data-to-transform-themselves>
- Micheli, M., Ponti, M., Craglia, M., & Suman, A. B. (2020). Emerging models of data governance in the age of datafication. *Big Data & Society*, 7(2), 1–15. <https://doi.org/10.1177/2053951720948087>
- 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>
- Mitra, A., Gaur, S. S., & Giacosa, E. (2019). Combining organizational change management and organizational ambidexterity using data transformation. *Management Decision*, 57(8), 2069–2091. <https://doi.org/10.1108/MD-07-2018-0841>
- Ng, K., & Liu, H. (2000). Customer Retention via Data Mining. *Artificial Intelligence Review*, 14(6), 569–590. <https://doi.org/10.1023/A:1006676015154>
- OECD. (2021). *The Digital Transformation of SMEs*. <https://doi.org/10.1787/dbd9256a-en>
- 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>
- Plotkin, D. (2014). Chapter 9 - Rating Your Data Stewardship Maturity. V *Data Stewardship: An Actionable Guide to Effective Data Management and Data Governance*. <https://apprize.best/science/stewardship/10.html>
- Power, D. J. (2000a). *Building Data-Driven Decision Support Systems. How do managers access and use large databases of historical and external facts?* <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.32.2655&rep=rep1&type=pdf>
- Power, D. J. (2000b). Web-Based and Model-Driven Decision Support Systems: Concepts and Issues. *Americas Conference on Information Systems (AMCIS)*, 352–355. <https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1871&context=amcis2000>
- Power, D. J., Burstein, F., & Sharda, R. (2011). Reflections on the Past and Future of Decision Support Systems: Perspective of Eleven Pioneers. V D. Schuff, D. Paradice, F. Burstein, D. J. Power, & R. Sharda (Ur.), *Decision Support: An Examination of the DSS Discipline* (str. 25–48). Springer New York. [https://doi.org/10.1007/978-1-4419-6181-5\\_2](https://doi.org/10.1007/978-1-4419-6181-5_2)
- Ramaprasad, A. (1983). On the definition of feedback. *Behavioral Science*, 28(1), 4–13. <https://doi.org/https://doi.org/10.1002/bs.3830280103>
- 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/pqdtglobal/docview/2461428896/fulltextPDF/337FD22C0C5B433BPQ/1?accountid=28931#>
- Rosenbaum, S. (2010). Data governance and stewardship: Designing data stewardship entities and advancing data access. *Health Services Research*, 45(5 PART 2), 1442–1455. <https://doi.org/10.1111/j.1475-6773.2010.01140.x>
- Simon, H. A. (1960). *The new science of management decision*. Prentice Hall.
- SMEDATA II. (b. d.). *SMEDData*. Pridobljeno 20. april 2021., od <https://smedata.eu/>
- Sorescu, A. (2017). Data-Driven Business Model Innovation. *Journal of Product Innovation Management*,

- 34(5), 691–696. <https://doi.org/10.1111/jpim.12398>
- 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. (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>
- Stahl, F., Schomm, F., Vossen, G., & Vomfell, L. (2016). A classification framework for data marketplaces. *Vietnam Journal of Computer Science*, 3(3), 137–143. <https://doi.org/10.1007/s40595-016-0064-2>
- 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>
- Trabucchi, D., & Buganza, T. (2019). Data-driven innovation: switching the perspective on Big Data. *European Journal of Innovation Management*, 22(1), 23–40. <https://doi.org/10.1108/EJIM-01-2018-0017>
- 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>
- Vijesh Joe, C., Raj, J. S., & Smys, S. (2020). Big Data Analytics: Tools, Challenges, and Scope in Data-Driven Computing. V J. S. Raj (Ur.), *International Conference on Mobile Computing and Sustainable Informatics* (str. 709–719). Springer International Publishing. [https://doi.org/10.1007/978-3-030-49795-8\\_67](https://doi.org/10.1007/978-3-030-49795-8_67)
- Weber, C., Königsberger, J., Kassner, L., & Mitschang, B. (2017). M2DDM – A Maturity Model for Data Driven Manufacturing. *Procedia CIRP*, 63, 173–178. <https://doi.org/10.1016/j.procir.2017.03.309>
- Wilkinson, M. D., Dumontier, M., Sansone, S.-A., Bonino da Silva Santos, L. O., Prieto, M., Batista, D., McQuilton, P., Kuhn, T., Rocca-Serra, P., Crosas, M., & Schultes, E. (2019). Evaluating FAIR maturity through a scalable, automated, community-governed framework. *Scientific Data*, 6(174), 1–12. <https://doi.org/10.1038/s41597-019-0184-5>