

Maja Vovko in Žiga Kovačič

MASOVNI PODATKI IN METODA DOSEGANJA TOČK

»Tehnološki in informacijski napredek v zadnjem času je močno vplival na to, kako organizacije poslujejo, postavljajo strategije, ohranjajo konkurenčno prednost in sprejemajo pomembne odločitve. Uporaba masovnih podatkov o zaposlenih v kadrovskem managementu je trenutno zelo nova praksa, ki pa se bo vse hitreje razvijala in vpeljevala. Za izkoristek prave dodane vrednosti uporabe masovnih podatkov v kadrovskem managementu bi morale organizacije tako vanje začeti vlagati že danes, vendar pa mora biti vpeljava prakse premišljena in dobro zastavljena.«

Danes skorajda z vsakim dejanjem, tako v fizičnem svetu kot na spletu, puščamo digitalne sledi, ki raziskovalcem lahko veliko povedo o vedenju in lastnostih posameznika. Lahko bi rekli, da sta danes komunikacija in vedenje posameznikov v veliki meri digitalizirana. Ideja masovnih podatkov (angl. *big data*) je zbiranje teh digitalnih sledi na način, ki omogoča analizo (Marr, 2015). Kaj sploh so masovni podatki in po čem se razlikujejo od tradicionalnih podatkov in baz, ki jih običajno organizacije zbirajo in obdelujejo? Ker so masovni podatki razmeroma nov pojav, je tudi njihova opredelitev še vedno v nastajanju, vendar pa se avtorji strinjajo glede štirih ključnih lastnosti masovnih podatkov, ki nam lahko pomagajo pri njihovi konceptualizaciji (npr. Chen, Chiang in Storey, 2012; Garcia-Arroyo in Osca, 2019; Roberts, 2013):

- **Količina oz. velikost podatkov**, ki jih organizacija pridobiva, zbira in hrani: masovni podatki so mnogo večji od tradicionalnih podatkovnih baz,

zato jih običajno ne hranijo na trdih diskih računalnikov, temveč v posebnih podatkovnih skladiščih (angl. *data warehouse*). Zaradi same količine podatkov po njih pogosto ni možno ročno brskati ali jih pregledovati, kot smo tega vajeni z drugimi zbirkami podatkov, temveč za pregledovanje in vpoglede v baze uporabljamo posebna, temu namenjena orodja in vmesnike. V zbirkah podatkov o zaposlenih, ki jih vodijo kadrovske službe, je navadno temu kriteriju hitro zadoščeno, saj so baze že običajno precej obsežne.

- **Hitrost oz. pretok pridobivanja podatkov:** v primerjavi s tradicionalnim zbiranjem podatkov po potrebi, npr. ob vstopu na delovno mesto, zamenjavi delovnega mesta, ob oceni delovne uspešnosti itd., masovni podatki v hrambo pritekajo dnevno ali celo neprestano. Tu je smiselno upoštevati naravo delovnega mesta, saj vsa ne omogočajo neprestanega pretakanja informacij, ker se te enostavno ne generirajo. Bolj dinamična, hitro spreminjajoča se delovna okolja, kjer se izvede veliko transakcij ali interakcij, kot so klicni centri ali večja skladišča, tako lahko zadostijo kriteriju (Fairhurst, 2014).
- **Raznolikost oblike in virov podatkov:** poleg demografskih podatkov, podatkov o kompenzacijah, uspešnosti na delu, raznolikih ocenjevanjih dela, številu odsotnosti, rezultatih vprašalnikov in podatkih o kompetencah v masovnih podatkih najdemo tudi nestrukturirane podatke, kot so izkušnje, elektronska sporočila, življenjepisi, objave na internih ali družbenih medijih (McCaffery idr., 2015). Podatke lahko zbiramo s pomočjo pametnih telefonov ali senzorjev, kar pa pri nestrukturiranih podatkih zahteva nove pristope k analizi. Raznolikost se nanaša na obliko oziroma format podatka, raznoliki pa so tudi viri, iz katerih informacije pritekajo v bazo.
- **Verodostojnost podatkov:** je ključna predvsem pri pregledu in oceni zbranih podatkov, saj se med zbiranjem raznolikih in številnih podatkov iz več virov in v različnih oblikah nabere tudi veliko »šuma« – podatkov, ki so morda nepopolni, največkrat tudi neuporabni ali neustrezni za želeno analizo ali problem.

Avtorji izpostavljajo, da za namen upravljanja in razvoja kadrov podatki ne potrebujejo nujno dosegati prav vseh kriterijev, da jih obravnavamo kot masovne. Ravno nasprotno – obstajala naj bi velika variabilnost že znotraj ene

organizacije, in sicer lahko določeni podatki ustrezajo vsem kriterijem, medtem ko so drugi mnogo bolj osnovni. Za uporabo masovnih podatkov, predvsem njihovih prednosti, tako ni treba imeti ogromnega podatkovnega skladišča in milijone bajtov raznolikih podatkov – prvi korak, ki ga mora kadrovski management (še) narediti, je že sam preskok iz intuitivnega, ustaljenega načina odločanja, v zavestno podpiranje kadrovskih odločitev z realnimi podatki ter njihovo preverjanje in dopolnjevanje (Fairhurst, 2014).

Poleg ključne lastnosti, da gre za mnogo večjo količino in pretok podatkov, ki so tudi v večji meri nestrukturirani kot v preteklosti, pa imajo masovni podatki v kontekstu kadrovskega managementa tudi nekatere druge lastnosti, ki jih ločujejo od tradicionalnih podatkovnih baz. Te lastnosti, ki so hkrati tudi glavne prednosti metode, povzemamo na podlagi sistematičnih pregledov (Garcia-Arroyo in Osca, 2019; Giacumo in Breman, 2016):

- podatki so sedaj še bolj vezani na ljudi (angl. *people-related data*);
- podatki so trenutni, zato je strah pred zastaranjem podatkov ali prepoznim ukrepanjem manjši;
- iz podatkov je mogoče v realnem času poiskati vzorce in oblikovati napovedne modele, ki so podpora pri sprejemanju odločitev (angl. *data-driven decision making*) in iz procesa odločanja odstranijo človeške napake ali pristranskosti;
- iz rezultatov in ugotovitev, ki jih omogočajo podatki, lahko dobimo uporabne rešitve za implementacijo.

Z uporabo masovnih podatkov bi kadrovske službe lahko pridobile veliko konkurenčno prednost, saj bi s pomočjo napredne analitike npr. prepoznale največje potenciale že med selekcijskim postopkom, izboljšale razmerje odhodov ter obdržale pri svojih zaposlenih zadovoljstvo, motiviranost in zavzetost. Z izboljševanjem tehnologije v ozadju, ki zmore hranjenje in obdelavo podatkov o zaposlenih na višjem nivoju, pa bo ta konkurenčna prednost, ki je trenutno še zelo redka, vse hitreje postala vsakodnevna praksa. Z vpeljavo metode bi tako morali kadrovski strokovnjaki začeti čim prej, da bi bil izkoristek čim večji (Fairhurst, 2014).

NASTANEK IN RAZVOJ METODE

Čeprav sprejemanje odločitev v kadrovskem managementu, tudi glede razvoja kadrov, že dolgo sloni na podatkih o zaposlenih, ki jih kadrovska služba zbira ali analizira, je velik tehnološki porast omogočil obstoj masovnih podatkovnih baz, ki so podlaga za napredno napovedno analitiko. Nastanek masovnih podatkovnih baz je v največji meri spodbudila digitalizacija podatkov; večina podatkov, ki se danes zbirajo, so v osnovi digitalni, njihova količina pa skozi leta eksponentno raste. Nadalje je s tehnološkim razvojem povezana rast samih podatkov, saj se večajo viri podatkov (tudi v kadrovski analitiki lahko npr. podatke sedaj zbiramo iz računalniških programov, mobilnih telefonov ali drugih naprav, ne pa le od zaposlenih samih), poleg količine se tako širi tudi vrsta in oblika podatkov. Naslednji pomemben prelom je bil razvoj storitev v oblaku, ki omogočajo enostavnejšo hrambo masovnih podatkov, ter računalniških programov in orodij za združevanje, urejanje, vpogled, čiščenje in predvsem analiziranje take ogromne količine informacij. Razvila so se tudi analitična orodja in njihove zmožnosti – sedaj lahko oblikujemo napovedni model, v katerega stalno pritekajo novi podatki, ki ga preverjajo in dopolnjujejo. V podatkih lahko iščemo tudi vzorce, kar pred nedavnim tehnološkim razvojem ni bilo mogoče (Murr, 2015).

Sprva se je najpogosteje zbiralo in analiziralo masovne podatke o strankah ali kupcih – z analizo masovnih podatkov so organizacije optimizirale in povečevale prodajo prek spoznavanja kupcev in njihovih nakupovalnih navad. S sledenjem trendom nakupov in nakupovalnih vedenj potrošnikov so lahko poiskali vzorce vedenj in napovedovali prodajo obstoječega ali novega izdelka. Za izboljšanje poslovnih procesov so z uporabo masovnih podatkov (npr. trendov na družbenih omrežjih, pogostosti iskalnih gesel v brskalnikih, celo vremenske napovedi) organizacije lahko na podlagi podatkovnega modela predvidele, kateri izdelek se bo prodajal, kar je vplivalo na poslovne odločitve v logističnih verigah in prerazporeditve skladišč. Vendar pa je uporaba hitro prerasla le prodajna podjetja – masovne podatke uporablja tudi policija v večjih mestih za lovljenje kriminalcev in napovedovanje povečanja kriminalne aktivnosti. Banke jih uporabljajo za odkrivanje nelegalnih transakcij bančnih kartic (Murr, 2015), masovni podatki pa so povezani tudi z razvojem interneta stvari (angl. *internet of things*).

Masovni podatki se v kadrovskih službah organizacij uporabljajo mnogo krajši čas kot na drugih poslovnih področjih – prvi strokovni prispevki, ki opisujejo možnosti prenosa prakse na kadrovske področje, segajo v leto 2013. V začetku je bila v ospredju uporaba masovnih podatkov na področju sprejemanja strateških kadrovskih odločitev, ocenjevanja uspešnosti in učinkovitosti ter izobraževanja in upravljanja z znanjem v organizaciji, pozneje pa se je pozornost usmerila tudi na selekcijo in iskanje ter ocenjevanje in razvoj kadrov (Garcia-Arroyo in Osca, 2019). Za uporabo masovnih podatkov v kadrovskem managementu se pojavljajo naslednja področja in raziskovalna vprašanja (Roberts, 2013):

- **Blagovna znamka delodajalca:** ali smo med iskalci zaposlitve začeli delodajalec? Kako nas kot zaposlovalca vidijo študenti z različnimi nivoji izobrazbe? Na kakšen način se študentje iz različnih univerz spoznavaajo z našo organizacijo?
- **Upravljanje s talenti:** kdaj in zakaj talenti zapustijo organizacijo? Zakaj določen oddelek izgublja več uspešnega kadra kot drugi?
- **Profiliranje talentov:** kakšne značilnosti, izkušnje, osebnost, večšine imajo vodje organizacije ali najbolj uspešni, učinkoviti zaposleni?
- **Načrtovanje kariernih poti zaposlenih:** kako pripraviti najbolj učinkovit, individualiziran načrt za posameznike ali skupine zaposlenih?
- **Načrtovanje nasledstev:** kako uspešno poiskati in razvijati prave naslednike za ključna delovna mesta?
- **Razvoj zaposlenih:** kdo so naši najbolj uspešni vodje ter katere lastnosti in kompetence jih ločijo od manj uspešnih? Kateri treningi so najbolj učinkoviti?
- **Ocenjevanje delovne uspešnosti posameznikov, timov ali oddelkov:** kateri timi so najbolj uspešni? Po kolikšnem času lahko pričakujemo, da bo novi zaposleni samostojen pri delu? Po čem se manj uspešni zaposleni razlikujejo od bolj uspešnih?
- **Segmentacija delovne sile:** kateri prodajniki so najbolj uspešni pri prodaji določenim segmentom strank? Kako določiti prave treninge in izobraževanja glede na močne in šibke točke zaposlenih?
- **Ovrednotenje raznolikih programov in pobud:** ocena učinkovitosti trenutne strategije zaposlovanja, učinkovitost treningov in izobraževanj.

- **Iskanje in selekcija kadrov:** kako doseči višji odziv na zaposlitvene oglase? Kako najti najbolj ustreznega kandidata za delovno mesto?
- **Ohranjanje kadrov:** kateri zaposleni bodo najverjetneje v kratkem zapustili organizacijo?

Čeprav so kadrovske prakse že prej temeljile na podatkih, je raba napovedne analitike za sprejemanje odločitev velik premik za kadrovski management (Roberts, 2013) in je trenutno na začetku svojega razvoja.

ZNANSTVENA SPOZNANJA O UPORABNOSTI METODE

Na področju rabe masovnih podatkov v kadrovskem managementu je praksa veliko pred empiričnimi znanstvenimi študijami, ki bi zagotavljale objektivni in merljiv vpogled v rezultate rabe takih podatkov. Večina objavljenih strokovnih prispevkov tematiko namreč preučuje s teoretičnega vidika ter tako predstavlja pregled in opise praks iz realnih podjetij v obliki študij primerov, opisuje možnost prenosa načinov uporabe iz drugih področjih (predvsem trženja in prodaje) na upravljanje s kadri ter raziskuje priložnosti in omejitve slednjega. Poleg tega predstavljajo praktične nasvete (metodološke, operativne in izvedbene) za vpeljavo metode. Pomemben delež teoretičnih strokovnih del, ki se ukvarjajo s problematiko in pomanjkljivostmi metode, izpostavlja prav potencialne pravne in etične dileme ter nujnost ustreznega upravljanja s tveganji (npr. Calvard in Jeskeb, 2018; Sodeman in Hamilton, 2018). Na podlagi študij primerov avtorji (Garcia-Arroyo in Osa, 2019; Giacumo in Berman, 2016) zaključujejo, da organizacije masovne podatke lahko (in ponekod že) uporabljajo za namene privabljanja in selekcije novih kadrov, priprave in ovrednotenja različnih razvojnih in izobraževalnih programov, ugotavljanje in izboljševanje zavzetosti pri delu, višanje retencije in nižanje fluktuacije zaposlenih itd.

Nekaj empiričnih študij sicer obstaja. Avtorji ugotavljajo, da je za uspešno pridobivanje znanj in informacij iz masovnih podatkov ključnega pomena skrb za ustrezno količino podatkov, hrambo, vzdrževanje in stalno reševanje težav (Mari in Masini, 2017). Drugi raziskovalci so

se ukvarjali s pripravo modela indikatorjev v organizaciji, ki so ključni pri tem, ali bo vpeljava uporabe masovnih podatkov uspešna ali ne. Izpostavljajo naslednje indikatorje uspešnosti: podpora vodstva, sposobnost vpeljevanja sprememb v organizacijo, infrastruktura IT, znanja in veščine strokovnjakov, ki proces vodijo, vsebina podatkov, strategija upravljanja s podatki ter skrb za varstvo in zaščito podatkov (Halaweh in El Massry, 2017). Preverili so tudi vpliv uporabe masovnih podatkov v trgovskih podjetjih na izboljšanje operativne uspešnosti – natančneje so pokazali, da lahko iz masovnih podatkov identificirajo ključne kazalnike učinkovitosti in jih nato uporabijo za vpeljavo hitrih sprememb v delovnem procesu. Čeprav je bila avtomatična vpeljava izboljšav uspešna, avtorji zaključujejo, da so prave zmožnosti uporabe masovnih podatkov na tak način še zelo nerazvite in se bodo v veliki meri razvijale dalje (Kitchin in Evans, 2018).

V splošnem gre za precej novo in zato še neraziskano področje, saj je prvo strokovno-znanstveno delo o tej temi objavljeno leta 2013, čeprav se število člankov in prispevkov vsako leto izrazito povečuje (Garcia-Arroyo in Osca, 2019; Giacumo in Breman, 2016). Za velik razkorak med dosežki v praksi in znanstvenimi raziskavami naj bi prišlo ravno zaradi specifičnosti metode. Organizacije, ki s pridom uporabljajo metodo za razvoj napovednih modelov in algoritmov za odločanje, so velika tuja podjetja, ki si to lahko privoščijo (npr. Google, IBM, Unilever), ostali pa operirajo z mnogo manjšimi podatkovnimi bazami, ki niso dovolj velike ali zrele za napredne analize. Še pomembnejši razlog se skriva v longitudinalnosti metode – zbiranje in priprava baze masovnih podatkov lahko traja več let in tako vzame precej več časa kot druge oblike raziskovanja.

Empirično podprta pa je uporaba s podatki podprtih praks in odločitev pri upravljanju s kadri. S pomočjo kadrovske analitike lahko tako organizacija na podlagi izračunov uspešnejše sklepa, kdaj bo prišlo do fluktuacij v delovni sili in pripravi ustrezne ukrepe (Lam in Chan, 2017), načrtujejo se lahko ukrepi za izboljšanje načrtovanja delovne sile in delovnega okolja (O'Brien-Pallas in Baumann, 2008), v splošnem pa naj bi organizacije, ki pri sprejemanju odločitev dajejo velik poudarek podatkom in poslovni analitiki, dosegale višje rezultate, bile poslovno bolj uspešne ter imele višjo dobičkonosnost kapitala (ROE) in tržno vrednost (Brynjolfsson, Hitt in Kim, 2011). S podatki podprte kadrovske

odločitve so zagotovo smiselne in učinkovite, v prihodnjih raziskavah pa bo treba preveriti, ali potrebna naložba v masovne podatke organizacijam res prinaša dodano vrednost, ki jo obljublja.

PREDSTAVITEV METODE

KDAJ METODO UPORABIMO?

Glavni namen masovnih podatkih je uporaba realnih in nazornih podatkov, ki so vezani na zaposlene. Z uporabo teh naj bi bolj strateško sprejemali odločitve, ki vplivajo na poslovanje, in izboljšali organizacijsko učinkovitost. Poglavitna ideja v ozadju analitične kadrovske službe pa je vnos znanosti, natančnosti in strogosti v procese, ki so tradicionalno v večji meri sloneli na intuiciji.

Drugi pomemben poudarek zagovornikov masovnih podatkov je upravljanje zaposlenih, ki prvenstveno temelji na dokazih. Gre za uporabo dokazov, podatkov ter analitično in kritično ovrednotenje le-teh pri sprejemanju menedžerskih odločitev, ki zmanjšuje tveganja, omogoča reševanje problemov v realnem času in ima vpliv na uspešnost organizacije (Garcia-Arroyo in Osca, 2019; Roberts, 2013).

Najbolj vabljiv vidik masovnih podatkov pa je vsekakor napovedljivost. Podatke lahko namreč obdelamo na osnovni ali kompleksni ravni, z nivojem obdelave pa so pogojeni tudi rezultati in odločitve. V organizacijah veliko kadrovske analize ostaja na deskriptivni ravni, katere omejena vrednost je ta, da ne omogoča enakega potenciala za iskanje rešitev. Stopnjo nad opisom pa je napoved, ki organizaciji že omogoči, da predvidi, kaj se bo zgodilo. Prav to je ključna vrednost masovnih podatkov (Roberts, 2013). Tako bi lahko s pomočjo napovedne analitike na trenutno najbolj uspešnih posameznikih v organizaciji oblikovali model, s katerim bi ocenjevali nove zaposlene – ti modeli bi temeljili na realnih podatkih in bi se razlikovali glede na področje dela ali delovno mesto, s tem pa postali maksimalno uporabni in veljavni.

Masovni podatki so tudi način za organizacije, da iz mnogih različnih podatkovnih baz zgradijo eno skupno bazo raznolikih informacij, katere nato združujejo za pridobivanje vrednih vpogledov, ki imajo lahko operativno ali celo strateško vrednost za organizacijo (Fairhurst, 2014).

Napovedovanje uspešnosti lahko poteka v resničnem času in tako ponudi vpoglede ter rešitve, ki že sproti skušajo izboljšati uspešnost. Tako ne čakamo na konec delovnega dneva, meseca ali celo leta za podajo povratne informacije o pričakovani uspešnosti. Organizacije najpogosteje napovedujejo odhode iz organizacije (Garcia-Arroyo in Osca, 2019), saj so ti lahko zelo škodljivi – s pomočjo napovednih modelov lahko odhode vnaprej predvidijo ter pripravijo retencijske programe za dvig zavzetosti, ki prav tako temeljijo na podatkih o zaposlenih. Naslednji korak po napovedovanju pa je samodejno sprejemanje odločitev, v ozadju katerega so napredki, kot sta strojno učenje in algoritmi, ki pa so trenutno še v razvoju in bodo pravo uporabno vrednost pokazali v prihodnosti (Fairhurst, 2014).

ZA KOGA JE METODA PRIMERNA?

Masovni podatki kot orodje bodo zagotovo najbolj zanimivi večjim podjetjem, ki že zbirajo in obdelujejo večje, tudi raznolike, baze podatkov o zaposlenih. Pri teh bo čas do učinkovite uporabe krajši, medtem ko morajo organizacije, ki podatkov v taki meri še ne uporabljajo, doseči določen nivo zrelosti podatkovnih baz. Kot omenjeno, ni nujno imeti ogromne ali kompleksne podatkovne baze, da organizacija začne z vpogledi v obstoječe podatke za sprejemanje boljših kadrovskih odločitev. S tega vidika je orodje primerno tudi za nekoliko manjše organizacije, čeprav ne gre za popolno uporabnost masovnih podatkov, z vsemi možnostmi, ki jih ponuja.

Zbiranje, hranjenje in analiziranje masovnih baz podatkov je smiselno predvsem za organizacije s takimi delovnimi mesti, ki omogočajo zvezno zbiranje raznolikih podatkov o zaposlenih. Zelo primerno je za dinamična delovna mesta z veliko interakcijami, ki jih lahko beležimo (predvsem prodajna podjetja, klicni centri, večja skladišča, logistični centri), saj se podatki ustvarjajo samodejno, treba jih je le zbrati, urediti in poiskati vredne informacije za izboljševanje delovne uspešnosti in učinkovitosti. Kjer je interakcij, ki jih lahko beležimo kot podatke, manj ali pa so si zelo podobne, bo težje zgraditi bazo masovnih podatkov.

Metoda je uporabna za kadrovske oddelke, ki želijo uporabiti (obstoječe ali novo zbrane) podatke o zaposlenih za sprejemanje odločitev

in pripravo razvojnih orodij. Kako kompleksni, poglobljeni ali veljavni bodo rezultati, pa bo odvisno od tega, kakšno bazo so zmožni zgraditi in kakšne analize je na bazi možno izvesti.

KAKO METODO IZVEDEMO?

Ker se z uporabo masovnih podatkov lahko lotimo zelo širokega nabora vprašanj, prav tako pa so tudi same baze med seboj zelo različne (po vsebini in velikosti), ni univerzalnega postopka za uporabo orodja. Organizacija bo morala svoje prakse prilagoditi vprašanjem, ki jih naslavlja, in podatkom, s katerimi razpolaga. V splošnem pa vpeljava masovnih podatkov v kadrovski management zahteva določene korake, s katerimi zagotovimo, da iz podatkov res pridobimo dodano vrednost. Spodaj povzemamo napotke avtorjev glede načina vpeljave orodja v kadrovski management (Davenport, 2013; Halaweh in El Massry, 2017; Tonidandel, King in Cortina, 2015):

1. Najprej je potrebno načrtovanje, kako bodo baze podatkov organizirane in upravljane. To vključuje odločitev o hranjenju podatkov (lokalno v računalniku ali na specializiranem mestu z več pomnilnika) in strukturiranosti (so baze povsem strukturirane in tako vedno pripravljene na uporabo ali manj strukturirane – v tem primeru je pred vsakim vpogledom potrebna priprava). Pri tem je treba upoštevati velikost podatkov, kako bo urejeno dostopanje do podatkov (kdo in kdaj) in njihovo pošiljanje.
2. V drugem koraku se uredi dostopanje do podatkov – pri kompleksnejših bazah, ki so navadno združbe več različnih podatkovnih baz, običajen vpogled namreč ni mogoč. Potrebno je znanje uporabe vmesnikov, ki omogočajo dostop do informacij. Oba koraka je smiselno dobro opredeliti tudi, preden se prične zbiranje novih podatkov, če vseh potrebnih še nimamo zbranih.
3. V tretjem koraku se podatke ureja in strukturira – ključno tu je ločevanje uporabnih informacij od neuporabnih oz. šuma, določanje kakovosti podatkov in odločitev, kaj storiti z manj kakovostnimi podatki. Potrebne so tudi odločitve o analizi, ki pa temeljijo na vrsti in formatu podatkov – nestrukturirani podatki, kot so vsebine

elektronskih sporočil, življenjepisi, video ali avdio posnetki, navadno zahtevajo posebno programsko opremo ali algoritme za analizo. Če so podatki preprostejši, se izvajajo opisne analize, bolj kompleksni, raznoliki in številčni podatki pa omogočajo iskanje povezav, trendov ali vzorcev, tudi napovedovanje.

4. Seveda se proces ne ustavi pri rezultatih; vpogleda ali napovedne modele je smiselno stalno preverjati z novimi ali dopolnjenimi podatki, ki se zbirajo v bazi.

PRIMER UPORABE METODE

Primer uporabe nove metode merjenja uspešnosti na podlagi masovnih podatkov, ki ga predstavljamo, izhaja sicer s področja športa, vendar so ključna sporočila razvoja te nove metode lahko zelo zanimiva za kadrovske strokovnjake, ki bi po njenem zgledu lahko razvijali po meri pripravljene načine merjenja uspešnosti ali katerekoli druge zelene metrike zaposlenih. Gre namreč za inovativen način uporabe podatkov na nov, prej neuporabljen način, ki je povsem spremenil merjenje uspešnosti v bejzbolu. V sredini 20. stoletja so v bejzbolu začeli številčno beležiti posamezne elemente igre, kar je analitikom pozneje omogočilo podrobno statistično analizo posamezne tekme. Teorija je bila revolucionarna predvsem zato, ker je pri analizi igre upoštevala druge vidike, ki do tedaj niso bili obravnavani kot pomembni napovedniki izida. Leta 2002 pa so te dodatne vidike igre začeli upoštevati tudi pri sestavljanju moštev.

Takrat se je v ZDA pojavila nova metoda novačenja igralcev bejzbola (metoda doseganja točk), ki je kot glavni kriterij igralčeve vrednosti vzela razmerje njegovih doseženih točk, bistveno manjšo vlogo pa je pripisala igralčevim lastnostim, kot so hitrost, moč odboja žogice in hitrost meta žogice, ki so jih do tedaj iskalci talentov dojemali kot glavne napovednike igralčeve uspešnosti. Te glavne kriterije so vodje moštev opazovali in ocenjevali pri mladih igralcih na fakultetah, kjer je bil cilj, da talent prepoznajo čim bolj zgodaj v karieri igralca, predvsem pa pred drugimi konkurenčnimi timi. Nabor igralcev je torej slonel na opazovanju igre, kjer naj bi tisti, ki so novačili, imeli poseben čut za dobre prihodnje igralce. Vendar tak način izbire ni upošteval drugih lastnosti

igralcev, npr. preteklih dosežkov, temveč je v veliki meri temeljil na občutkih in predpostavkah. Z metodo dosega točk pri naboru so prvič uporabili analizo podatkov o igralcih (Fairhurst, 2014).

S pomočjo bogatih podatkovnih baz o tistih lastnostih igralcev, ki so postali novi kriteriji določanja njihove vrednosti, in naprednejših statističnih metod, so razvili nov način oblikovanja bejzbol ekip, ki so ga imenovali **metoda doseganja točk** (angl. *sabermetrics*; izraz izvira iz ameriške kratice SABR za Zvezo razvoja ameriškega bejzbola – *Society of American Baseball Research*). Takrat revolucionarna metoda, saj je temeljila na statističnih analizah, je menedžerjem, ki so prvi začeli z njeno uporabo, omogočila sestavo konkurenčnih ekip z bistveno manjšim finančnim vložkom, kot so jih za sestavo ekip porabili drugi klubi. Tim, ki je imel za sestavo ekipe zelo omejena finančna sredstva, je tako v tej sezoni nepričakovano dosegel kar 20 zaporednih zmag. Kriteriji, ki so jih za določanje igralčeve vrednosti uporabljali pri sestavljanju ekip z metodo dosega točk, so pokazali, da so nekateri igralci zelo podcenjeni, kljub njihovi visoki dodani vrednosti za ekipo. Ključnega pomena pri sestavi dobrih ekip po tej metodi je tudi izbira igralcev, ki sicer ne dosegajo najvišjih rezultatov na vseh kriterijih, a se s svojimi prednostmi medsebojno dopolnjujejo in tako skupaj tvorijo celoto, ki dobro funkcionira na vseh področjih.

Ta metoda, ki je bila prvotno namenjena sestavljanju bejzbol ekip, pa je uporabna tudi na področju kadrovskega menedžmenta v organizacijah (Wolfe, Wright in Smart, 2006). Kot je v bejzbolu glavna strategija nakup igralcev, ki bodo izboljšali možnost za zmago ekipe, morajo tudi organizacije zaposliti delavce, ki so zmožni opravljati delovne naloge, ki jih določa strategija njihove organizacije. Ali bo organizacija zaposlila določenega posameznika, je odvisno od tega, do kolikšne mere ta posameznik zadošča kriterijem, ki določajo njegovo vrednost v smislu potencialnega doprinosa za organizacijo. Kot so v bejzbolu spremenili način sestavljanja moštev, bi lahko na področju kadrovskega menedžmenta npr. spremenili metodo sestavljanja delovnih timov po zgledu metode dosega točk ali pa oblikovali boljše kriterije primernosti kandidatov za določena delovna mesta (Wolfe, Wright in Smart, 2006). S pomočjo bogatih podatkovnih baz o zaposlenih bi lahko v številnih organizacijah posodobili kriterije ter zaposlovali tiste, ki s svojimi kompetencami

dopolnjujejo tim, kar bi organizacijam omogočilo sestavo uspešnih delovnih timov. V ospredje lahko namesto sestavljanja timov organizacija seveda postavi kak drug kadrovski problem in se ga loti s pregledom že zbranih podatkov o zaposlenih za izboljšanje načinov dela in odločanja. Ključni doprinos metode dosega točk je namreč spoznanje, da le uporaba do sedaj uveljavljenih kriterijev ali prenos kriterijev iz druge organizacije v lastno, ni nujno prava izbira, ki bi omogočila boljše odločitve ali postopke. Organizacija mora prepoznati lastne potrebe ter specifike in uporabiti realne, obstoječe podatke, da preveri, ali so obstoječe značilnosti in kriteriji ustrezni ali pa je morda čas za nove.

VLOGA PSIHologa

Ključno pri dobri in ustrezni rabi masovnih podatkov je razumevanje poslovne strategije ter preoblikovanje obstoječih poslovnih vprašanj v raziskovalne probleme (Fairhurst, 2014). Psiholog je s svojimi znanji lahko pomemben član pri vpeljavi metode, saj zna zastaviti raziskovalno vprašanje, izbrati prave podatke (tudi hraniti, obdelovati, čistiti), jih analizirati (z osnovnejšimi opisnimi ali inferenčnimi analizami, lahko pa tudi kompleksnejšimi napovednimi modeli), prikazati ter jasno in jedrnatost predstaviti odločevalcem na način, ki bo podprl in olajšal proces odločanja. Za slednjo so ključne dobro razvite komunikacijske sposobnosti. Pri kadrovski analitiki je namreč ključen pristop »od zgoraj-navzdol« – najprej se torej pojavi problem (identificira ga navadno vodstvo organizacije), nato pa se za potrebe iskanja rešitev postavi vprašanje in pregleda ali celo zbira podatke.

Za upravljanje zelo visoko kompleksnih baz masovnih podatkov imajo tuje organizacije navadno oddelke, namenjene zbiranju ali združevanju takih baz, tako imenovane kadrovske analitične oddelke. Če ima organizacija tak oddelek, v njem pa zaposlenega psihologa s potrebnim znanjem (strokovnjak za analitiko HR), navadno sam zbira te podatke. Če podatke zbira več različnih oddelkov znotraj organizacije, je naloga analitika HR, da od drugih oddelkov vse podatke pridobi in združi. Podjetje lahko strokovnjaka za analitiko HR tudi najame, navadno kadar je organizacija premajhna ali premlada, da bi zaposlila svojega. Kot omenjeno, pa so masovni podatki organizacije lahko na različnih

nivojih kompleksnosti. Tako lahko določene analize psiholog na »manjših« podatkovnih bazah opravlja povsem samostojno, kjer bi za upravljanje kompleksnejših procesov ali baz potreboval dodatna znanja podatkovne znanosti. Delovna mesta kadrovikov bodo namreč v prihodnosti zahtevala predvsem analitične sposobnosti za uspešno uporabo bogatih podatkovnih baz o zaposlenih (Carrig in Wright, 2006).

Pri delu z masovnimi podatki je nujno posvečati dodatno pozornost varovanju zasebnosti in skrbi, da so prakse skladne z Zakonom o varstvu osebnih podatkov in uredbo GDPR, ter da so nameni obdelovanja podatkov etični. Upoštevanje zasebnosti je tu velik izziv, saj niti anonimizacija podatkov ni več ustrezna rešitev. Tuji avtorji namreč poudarjajo, da zakritje imena ne skrije identitete, saj jo je sedaj zaradi dostopnosti množičnih in raznolikih podatkov o posamezniku lažje odkriti (Roberts, 2013). Vloga psihologa je, da je pozoren na varovanje identitete, varovanje dostopnosti podatkov (nadzor in omejitev posredovanja tretjim osebam), pa tudi na zaznave zaposlenih o zbiranju in uporabi takih podatkov. Če organizacija v večji meri zbira in hrani podatke zaposlenih, je treba k temu pristopiti previdno in zaposlenim predstaviti prakse varovanja etičnih načel, da preprečimo negativne predstave zaposlenih o teh praksah.

PREVIDNOST IN OMEJITVE PRI UPORABI METODE

Največji izziv organizacij pri vpeljevanju uporabe masovnih podatkov za kadrovske management je to, da je potrebno podjetje, njegovo poslovanje in strategijo zelo dobro razumeti, preden lahko konceptualiziramo in opredelimo raziskovalna vprašanja, na katera bi odgovarjali s pomočjo napovedne analitike (Fairhurst, 2014). Očitna omejitev je tudi samo zbiranje masovnih podatkov o zaposlenih – mnogo organizacij ne zbira množstva podatkov in tako nima »zrele baze«, na kateri bi lahko izvajala analize in napovedovala vedenja. Če organizacija začne z zbiranjem podatkov danes, bodo podatki dovolj »zreli« šele čez nekaj let (Roberts, 2013). Hkrati kopičenje takih podatkov predstavlja velik časovni in ekonomični strošek za organizacijo. Posledično je morda nekoliko primernejše za zrela ali večja podjetja. Upoštevati je treba tudi metodološke

omejitve – zaradi količine podatkov so povezanosti pogosteje naključne ali prenapihnjene, potrebna pa je tudi stalna skrb za kakovost podatkov (izločanje šuma) (Garcia-Arroyo in Osca, 2019).

Pomanjkljivost, ki se navezuje na psihologe v organizaciji, pa je predvsem ta, da ti v osnovi niso izobraženi za zbiranje in obdelovanje take količine podatkov, ki v različnih oblikah prihajajo iz različnih virov. Četudi so izučeni v poznejših fazah analize, sporočanja ugotovitev in prikazovanja le-teh, so za upravljanje z masovnimi podatki potrebna tudi matematična in programerska znanja, npr. priprava algoritmov, napredne napovedne analize ter strojno učenje. Najbolj težavno pri vpeljavi masovnih podatkov naj bi bilo ravno izluščiti uporabne informacije (Garcia-Arroyo in Osca, 2019). Zagotovo bi bila potrebna identifikacija prednosti pridobivanja teh znanj ter posledično vstop v dodatno izobraževanje, večje baze masovnih podatkov pa zahtevajo tudi sodelovanje različnih oddelkov v organizaciji (kadrovska služba, trženje, poslovna inteligenca, informacijska tehnologija). Trenutna omejitev je tudi to, da je uporaba masovnih podatkov v kadrovske službi dokaj nova praksa, zato je dostop do relevantnih raziskav, primerov praks in etičnih usmeritev zelo omejen.

L I T E R A T U R A

- Brynjolfsson, E., Hitt L. M. in Kim, H. H. (2011). Strength in numbers: how does data-driven decisionmaking affect firm performance? *SSRN Electronic Journal*. Dostopno na <https://ssrn.com/abstract=1819486>
- Carrig, K. in Wright, P. (2006). Building profit through building people: Making your workforce the strongest link in the value-profit chain. *Arlington: Society for Human Resource Management*.
- Calvard, T. S. in Jeskeb, A. (2018). Developing human resource data risk management in the age of big data. *International Journal of Information Management*, 43, 159–164.
- Chen, H., Chiang, R. H. L. in Storey, V. C. (2012). Business intelligence and analytics: From big data to big impact. *MIS Quarterly: Management Information Systems*, 36(4), 1165–1188.
- Davenport, T. H. (2013). *Enterprise analytics: Optimize performance, process, and decisions through big data*. Hoboken, NJ: Pearson Education.

- Evans, L. in Kitchin, R. (2018). A smart place to work? Big data systems, labour, control and modern retail stores. *New Technology, Work and Employment*, 33(1), 44–57.
- Fairhurst, P. (2014). Big data and HR analytics. V P. Reilly in P. Tamkin (ur.), *IES Perspectives on HR 2014: HR responding to threats and opportunities*. Institute for Employment Studies, Brighton: UK.
- Garcia-Arroyo, J. in Osca, A. (2019). Big data contributions to human resource management: a systematic review. *The International Journal of Human Resource Management*, 1–26.
- Giacumo, L. A. in Breman, J. (2016). Emerging evidence on the use of big data and analytics in workplace learning: A systematic literature review. *Quarterly Review of Distance Education*, 17(4), 21–38.
- Halaweh, M. in El Massry, A. (2017). A synergetic model for implementing big data in organizations: An empirical study. *Information Resources Management Journal*, 30(1), 48–64.
- Lam, S. in Chan, A. (2017). Data-driven HR: Creating a turnover response plan based on the Kaplan-Meier estimator. *Journal of American Water Works Association*, 109(2), 37–41.
- Mari, F. in Masini, P. (2017). Big data at work: The practitioners' point of view. *IEEE Instrumentation & Measurement Magazine*, 20(5), 13–20.
- Marr, B. (2014). *Big data: The four layers everyone must know*. Dostopno na <https://www.linkedin.com/pulse/20140918062736-64875646-big-data-the-4-layers-everyone-must-know/>
- O'Brien-Pallas, L. in Baumann, A. (2008). Toward evidence-based policy decisions: A case study of nursing health human resources in Ontario, Canada. *Nursing Inquiry*, 7(4), 248–257.
- Roberts, B. (2013). The benefits of big data. *HR Magazine*, 58(10), 21–30.
- Sodeman, W. A. in Hamilton, B. (2018). *Legal and ethical challenges for human resources in the big data era*. Prispevek predstavljen na Academy of management specialized conference on big data and managing in a digital economy, Academy of management, Surrey, UK.
- Tonidandel, S., King, E. B. in Cortina, J. M. (ur.). (2015). *Big data at work: The data science revolution and organizational psychology*. New York, NY: Routledge.
- Wolfe, R., Wright, P. in Smart, D. (2006). Radical HRM innovation and competitive advantage: The Moneyball story. *Human Resource Management Journal*, 45(1), 111–145.

BIG DATA AND SABERMETRICS

Recent technological and informational advances have had an important impact on how organizations do business, set strategies, keep their competitive advantage and make important decisions. Collecting and analysing a huge amount of data about diverse transactions and interactions (i.e. big data) is now possible due to the rise of both the quantity of data produced and tools for using them. Organizations use big data to develop predictive models, automate decision-making and enhance their business results. On the other hand, the use of big data in human resource management is a fairly new practice, which will keep developing and soon become the new normal. However, to truly benefit from the competitive advantage of big data insights in HR management, organizations have to start developing their practices today. In this context, special attention and thought need to be put into the introduction of this new practice.