GODINA
HRVATSKE
NARODNE
BANKE

Istraživanja I-62

Procjena spremnosti hrvatskih poduzeća na uvođenje tehnologija I4.0

Rajka Hrbić, Tomislav Grebenar

Zagreb, ožujak 2021.

HRVATSKA NARODNA BANKA · CROATIAN NATIONAL BANK

Navodi u tekstu stavovi su autora te ne moraju nužno izražavati stajalište ili mišljenje Hrvatske narodne banke.

Assessment of Readiness of Croatian Companies to Introduce I4.0 Technologies

Abstract

The main topic of this paper is to estimate the possibility and inclination of Croatian companies towards technology and inovation as well as to analize advantages, limitations and risks involved with this significant technological leap. In this paper, we analized 7.147 of Croatian business entities operating in different industries. Starting point in this research is to identify other subjects which could be users of I4.0 or its elements, based on the simmilarity of indicators with indicators of a sample of 58 identified I4.0 companies. We developed machine learning model by using eXtreme Gradient Boosting algoritm (XGBoost) for this purpose, an approach which has not been used in any similar reserches.

This research shows that the main difference between I4.0 and traditional industry is mostly observable in significantly better businesess performance of investment indicators, cost efficiency, technical equipment and market competitivness. Riskiness of I4.0 companies is significantly lower than the riskiness of traditional ones.

We identified 141 companies (1,97% of total analized sample) as potential users of I4.0, which make around 27% of total assets of the analised sample and around 26% of revenues.

Keywords: Industry 4.0, eXtreme Gradient Boosting (XGBoost), artificial intelligence, robotics, high-tech companies, machine learning, impacts of I4.0 on bussines results

JEL: C45, D22, D24, O14, O32, O33

Sažetak

Tema je rada procjena mogućnosti i spremnosti hrvatskih poduzeća za jačanje tehnološko-inovativnog potencijala te analiza prednosti, ograničenja i rizika koje donosi značajan tehnološki skok. Analizirano je 7147 hrvatskih poslovnih subjekata iz različitih djelatnosti. Polazna je točka istraživanja prepoznavanje poduzeća koja potencijalno rabe tehnologiju I4.0, na temelju sličnosti njihovih pokazatelja s pokazateljima 58 poduzeća iz uzorka nedvojbeno identificiranih korisnika i proizvođača tehnologije I4.0. U tu je svrhu razvijen i upotrijebljen model strojnog učenja s pomoću algoritma *eXtreme Gradient Boosting*, što do sada nije bilo primijenjeno u sličnim istraživanjima.

Istraživanjem je pokazano da su glavni razlikovni elementi između I4.0 i tradicionalnih poduzeća najizraženiji kao osjetno bolje poslovne performanse u pokazateljima investiranja, troškovne efikasnosti, tehničke opremljenosti i tržišne konkurentnosti. Rizičnost I4.0 poduzeća značajno je niža od rizičnosti tradicionalnih poduzeća.

U istraživanju je identificirano 141 poduzeće (1,97% analiziranih subjekata) s potencijalom za I4.0, što čini oko 27% aktive analiziranog uzorka te oko 26% poslovnih prihoda.

Ključne riječi: industrija 4.0, *eXtreme Gradient Boosting* (*XGBoost*), umjetna inteligencija, robotika, visokotehnološka poduzeća, strojno učenje, utjecaj I4.0 na poslovne rezultate

JEL: C45, D22, D24, O14, O32, O33

Sadržaj

Abstract ... 3

Sažetak ... 4

Sadržaj ... 5

1. Uvod ... 6

2. Utjecaj industrije 4.0 na poslovanje poduzeća ... 7

2.1. Pojam i primjena industrije 4.0 ... 7

2.2. Prethodna istraživanja i pregled literature ... 10

3. Prepoznavanje potencijala za I4.0 s pomoću strojnog učenja ... 11

3.1. Podaci ... 12

3.2. Hipoteza i pretpostavke ... 13

3.3. Model za procjenu potencijala primjene I4.0 ... 17

3.3.1. Procjena modela strojnim učenjem ... 21

4. Analiza rezultata ... 23

4.1. Analiza potencijala I4.0 na cijelom skupu (neprobabilistički uzorak) ... 23

4.2. Poslovne performanse i rizičnost I4.0 poduzeća ... 27

5. Zaključak i implikacije rezultata za ekonomsku politiku ... 33

Dodatak A. ... 35

Dodatak B. ... 38

Dodatak C. ... 42

O strojnom učenju ... 42

Logistička regresija ... 46

Literatura ... 49

Popis slika i tablica ... 51

1. Uvod

Ovo istraživanje procjenjuje spremnost hrvatskih poduzeća za jačanje tehnološko-inovativnog potencijala, kao i prednosti, ograničenja i utjecaj na rizičnost poduzeća koje sa sobom donosi četvrta industrijska revolucija. Rad analizira ključne pokazatelje poslovanja i rizičnost I4.0[1] poduzeća u Hrvatskoj te ih uspoređuje s "tradicionalnim" poduzećima iz istih ili sličnih djelatnosti.

I4.0 utječe na razvoj poduzeća, financijski sektor pa time i ukupno gospodarstvo. Ulaganja u nove tehnologije pozitivno utječu na rast BDP-a putem povećanih investicija i produktivnosti (konkurentnosti). Ulaganje u tehnologiju zahtijeva velika financijska sredstva, što dovodi do rasta potražnje za kreditima. Srž je četvrte industrijske revolucije umjetna inteligencija, odnosno primjena strojnog učenja, a posebno tzv. dubokog učenja: algoritma za prepoznavanje stanja sustava i autonomno odlučivanje s ciljem optimizacije procesa. Riječ je o sofisticiranim uređajima koji rabe umjetnu inteligenciju i tehnologijama koje skraćuju istraživačko-razvojne projekte u dizajnu (CAD), razvoju prototipova, simulacijama i upravljanju procesima u proizvodnji ili komunikaciji. Tehnologija koju I4.0 pruža jedna je od najvećih mogućnosti za razvoj gospodarstva danas. Zanimljivost je ovog rada u tome što primjenjuje upravo model dubokog učenja kakvim se koriste napredni sustavi tehnologije I4.0 – duboko strojno učenje na uzorku evidentiranih korisnika ili proizvođača tehnologije I4.0.

Analizom dosadašnjih istraživanja i pregledom literature ustanovljeno je da postoji potreba za ovakvim istraživanjem kako bi se s pomoću sofisticirane tehnike strojnog učenja procijenila spremnost poduzeća i njihov potencijal za uvođenje I4.0 na području Republike Hrvatske. Rad je strukturiran tako da nakon prvog, uvodnog poglavlja, slijedi drugo poglavlje, koje objašnjava pojam i ulogu četvrte industrijske revolucije te daje pregled teorije i prethodnih istraživanja. Treće se poglavlje odnosi na prepoznavanje potencijala za I4.0 s pomoću strojnog učenja. Četvrto je poglavlje analiza rezultata. U zaključnom su poglavlju dane implikacije na ekonomiju i ekonomsku politiku, odnosno povezuju se glavni rezultati rada (detektirani potencijali) s politikama koje bi trebale biti u stanju poduprijeti razvoj poduzeća u smislu uvođenja novih tehnoloških rješenja četvrte industrijske revolucije. Dodaci sadržavaju detaljnije informacije o upotrijebljenim varijablama i kratke osnove strojnog učenja.

[1] Umjetna inteligencija, robotika i ostale tehnologije visokog stupnja autonomije

2. Utjecaj industrije 4.0 na poslovanje poduzeća

2.1. Pojam i primjena industrije 4.0

Industrija 4.0 ili kraće I4.0, odnosno I4 zasniva se na automatiziranoj tehnologiji umreženoj putem senzora i komunikacijskih elemenata (Blunck i Werthmann, 2017.) te na taj način povezuje realan i virtualan svijet u obliku tzv. *cyber-physical* sustava, kao što su npr. autonomni roboti. Za razliku od tradicionalnih proizvodnih sustava s centraliziranom kontrolom koja svaki pojedinačni stroj smatra neovisnom jedinicom, tzv. tvornica 4.0 povezuje strojeve u svojevrsnu zajednicu koja je u uzajamnom djelovanju i suradnji, autonomno i "inteligentno". Upotreba naprednih alata za predviđanje omogućuje kontinuiranu obradu velikih podataka (engl. *big data*) radi odlučivanja utemeljenog na svim dostupnim informacijama u svakom trenutku, što je temelj razvoja umjetne inteligencije (UI, engl. *AI*).

Postoje različite definicije industrije 4.0, no zajedničko im je to da obuhvaćaju tehnologije koje vode prema automatizaciji određenih procesa pri proizvodnji i/ili pružanju usluga. To su trodimenzionalni ispis, umjetna inteligencija, proširena stvarnost, roboti, veliki podaci, *Blockchain*, tehnologija oblaka, "cobotic" sustavi sa suradnjom ljudi i robota – kolaborativni sustavi, kibersigurnost, dronovi, GPS (*Global Positioning System*), industrijski internet stvari, mobilna tehnologija, nanotehnologija, RFID (tehnologija koja upotrebljava bežičnu komunikaciju i automatski prati i identificira određene objekte), senzori i simulacije (Dalenogare *et al.*, 2018.; Lu, 2017.; Wan *et al.*, 2015.; Posada *et al.*, 2015. prema Bai *et al.*, 2020.).

U ovom radu poduzeća koja se koriste pojedinim elementima četvrte industrijske revolucije ili planiraju preinaku načina poslovanja prema konceptu industrije 4.0 identificirana su na temelju sljedećih tehnologija (BCG – Boston Consulting Group):

1. veliki podaci i analize
2. autonomni roboti
3. simulacije
4. horizontalne i vertikalne integracije sustava
5. industrijski internet stvari
6. kibersigurnost
7. oblak
8. trodimenzionalni ispis
9. proširena stvarnost.

Pri određivanju činjenice je li neko poduzeće I4.0 ili nije, važan je cjeloviti pristup tehnologijama kojima se služi. Neka se poduzeća koriste pojedinim od navedenih tehnologija, no to ne znači da se ona u potpunosti smatraju industrijom 4.0. Ovisno o stupnju primjene tih tehnologija možemo zaključiti je li određeno poduzeće na putu prema ostvarenju koncepta I4.0. Razlike među poduzećima mogu biti značajne, od

toga da postoji potpuno automatizirano poduzeće koje primjerice robotima proizvodi robote (Japan kao sinonim za robote i robotiku) do poduzeća koja postupno prihvaćaju određene segmente nove industrijske revolucije.

Tehnologija svake od prethodne tri industrijske revolucije (parni strojevi, električna energija, informacijske tehnologije) bila je iznimno otkriće i napredak, pa se to događa i u aktualnoj revoluciji. Ovim će promjenama biti zahvaćena brojna područja kao što su poslovno upravljanje, financije, zdravstveni sektor, energetika, transport, industrija, uslužne djelatnosti, intelektualne usluge i brojna druga područja poput genetike i biotehnologije. Istraživanje Frey i Osborne, 2013., procjenjuje osjetljivost trenutačnih poslova na tehnološki razvoj. Prema toj procjeni 47% ukupne zaposlenosti u SAD-u pripada kategoriji visokog rizika. Model primijenjen u navedenom istraživanju predviđa drugačiji trend polarizacije tržišta rada od postojećeg. Kako tehnologija napreduje, prema spomenutom istraživanju o budućnosti zaposlenosti, radnici s nižim vještinama preraspodjeljuju se na zadatke koji zahtijevaju kreativnu i socijalnu inteligenciju. No promjene će zahvatiti i visokoobrazovane stručnjake (primjer IBM Watson), što će utjecati na područje prava ili zdravstva (dijagnostika). Google je umjetnu inteligenciju iskoristio kao "Google Duplex", virtualnog asistenta koji može dogovarati sastanke ili termine razgovarajući sa stvarnim osobama, čak i onima koji ne znaju dobro jezik. Zbog teme ovog rada potrebno je istaknuti i područje kreativne umjetne inteligencije koja može dati nova kreativna tehnološka rješenja obradom velikih podataka.[2]

Ekonomske prednosti navedene kao svojevrsni "pokretači" četvrte industrijske revolucije (McKinsey prema Blunck i Werthmann, 2017.) jesu upotreba resursa i optimizacija poslovnog procesa (primjerice smanjenje materijalnih troškova zbog praćenja proizvodnog procesa u realnom vremenu, smanjenje vremena čekanja između različitih proizvodnih koraka u proizvodnji te ubrzanje procesa istraživanja i razvoja rezultiraju povećanjem produktivnosti). Optimalna upotreba imovine, upravljanje zalihama, povećanje produktivnosti, poboljšanje kvalitete proizvoda i usluga, smanjenje potrebnog vremena od prototipa do stavljanja proizvoda na tržište, smanjenje troškova postprodajne usluge i podrške klijentima, servisiranje i održavanje proizvoda s pomoću virtualnih asistenata i slično samo su neke prednosti primjene industrije 4.0.

Industrijsku revoluciju četvrte generacije najviše određuju sljedeće tehnologije.

Umjetna inteligencija najviše se upotrebljava za interakciju s okolinom, prepoznavanje slike (statičke ili u pokretu), ljudskog govora i stanja okoline (temperature, vlage, pozicije, brzine, smjera kretanja i sl.) te obradu prikupljenih podataka u realnom vremenu s ciljem autonomnog i iskustveno optimiranog upravljanja nekim procesom. Ne postoji općeprihvaćena definicija umjetne inteligencije. Najšira je primjena umjetne

[2] Na primjer, u avioindustriji pri projektiranju profila koji se odlikuju iznimnom čvrstoćom i malom masom (primjer koncepta Airbusa A-320 koji smanjuje masu određenih dijelova i do 45% u odnosu na tradicionalne modele, što znatno smanjuje potrošnju goriva i emisiju CO2 i drugih stakleničkih plinova, a upotrebom 3D ispisa i utrošak sirovina do čak 95%).

inteligencije u robotici koja se upotrebljava ponajviše u proizvodnim procesima, transportu, dizajnu, inženjeringu, financijama, informatici, dijagnostici, a sve više i u kućanstvima te industriji zabave.

"Veliki podaci" (engl. *Big Data*) postaju standard u podršci pri donošenju odluka u stvarnom vremenu. Podaci se prikupljaju iz više izvora, npr. proizvodne opreme i sustava te sustava upravljanja poduzećima i klijentima. Kako bi upotreba velikih podataka imala uporabni smisao, potrebno je konsolidirati i procijeniti takve podatke na inteligentan način (Sauter *et al.*, 2015., str. 5 prema Blunck i Werthmann, 2017.).

Roboti su u međusobnoj interakciji i rade "u suradnji" s ljudima te uče od njih. Troškovi će biti niži, a mogućnosti šire nego u današnjoj proizvodnji. Robotika je jedan od temelja industrije 4.0 te roboti i ljudi sve više postaju ravnopravni u poslovnim procesima.

Simulacije se najviše upotrebljavaju da bi se fizički svijet prebacio u virtualni model u svrhu smanjenja troškova i povećanja kvalitete. One omogućuju operaterima testiranje i optimizaciju postavka strojeva za sljedeći proizvod prije fizičke proizvodnje.

Horizontalne i vertikalne integracije sustava omogućuju bolju koheziju između odjela i funkcija, jer sveobuhvatne mreže podataka razvijaju automatizirane lance vrijednosti.

Internet stvari (engl. IoT, *Internet of Things*) u industriji 4.0 znači da će u uređajima biti ugrađena računala u svrhu omogućavanja njihove međusobne komunikacije. Blunck i Werthmann (2017.) opisuju ga kao "ekosustav" tehnologija koje nadziru status fizičkih objekata. U isto vrijeme mjere bitne podatke i prenose takve informacije aplikacijama preko mreža. Svaka definicija interneta stvari sadržava: pametne objekte, komunikaciju stroja sa strojem (engl. *machine to machine*, M2M) te radiofrekvencijske tehnologije (Thrasher, 2014. prema Blunck i Werthmann, 2017.).

Kibersigurnost je nužnost koja proizlazi iz povećanja povezanosti i upotrebe standardnih komunikacijskih protokola. Podrazumijevaju se sigurne, pouzdane komunikacije te upravljanje identitetom i pristupom strojevima. Prema posljednjem dostupnom Izvješću o radu Europske investicijske banke (EIB, 2018.) istaknuta je upravo tema kibernetičke sigurnosti. U Izvješću se naglašava da su tijekom posljednjeg razdoblja kibernetički napadi ugrozili tisuće poduzeća i podatke milijarda ljudi.

Tehnologija "oblaka" omogućava povezivanje pri proizvodnji i zahtijeva veću razmjenu podataka. Performanse tehnologija u oblaku poboljšat će se u smislu vremena reakcije, a rezultat je omogućivanje više podatkovnih usluga.

Trodimenzionalni ispis sve se više upotrebljava zbog svojih konstrukcijskih prednosti za izradu prototipova i pojedinačnih komponenata ili za proizvodnju malih serija posebno prilagođenih proizvoda. Radi se o iznimnoj revoluciji kakva je prije 570 godina

bio Gutenbergov tiskarski stroj. Mogućnosti su trodimenzionalnog ispisa impresivne, od upotrebe za tehnologiju NASA-e, u avioindustriji, ali i za ispis organa (npr. uha, bubrega i sl.) s pomoću pacijentovih stanica. Ekonomski je zanimljivo područje i ispis hrane.

Proširena stvarnost podržava raznovrsne usluge i omogućava informacije u stvarnom vremenu. Rezultat ove tehnologije može biti bolje donošenje odluka i/ili obavljanje postupaka.

2.2. Prethodna istraživanja i pregled literature

Istraživanje PwC (2014.) prikazuje kako industrijska poduzeća mogu ostvariti nove prilike za gospodarski razvoj upotrebljavajući I4, ali govori i o mogućim izazovima. Istraživanje je provedeno na pet ključnih industrijskih sektora[3] iz baze 235 njemačkih industrijskih poduzeća. Autori procjenjuju da će udio investicija u tehnologiju I4.0 biti viši od 50% planiranih kapitalnih investicija u petogodišnjem razdoblju. Isto tako, njemačka će industrija investirati oko 40 milijarda eura u I4 svake godine sve do 2020. Ispitana poduzeća očekuju povećanje produktivnosti od 18% u sljedećih pet godina. Internet stvari ili usluga pridonijet će porastu prihoda od 2% do 3% na godinu, što će na razini njemačke industrije biti povećanje od 30 milijarda eura.

Izvješće agencije Cerved (2017.) o malim i srednjim poduzećima analizira i plan talijanske vlade za I4.0 radi stimuliranja inovacija, investicija te istraživanja i razvoja. Primijenjena je metoda klasteriranja zasnovana na sklonosti poduzeća inovacijama i investicijama, pri čemu su inovacijama sklona poduzeća ostvarivala veći rast prihoda i bolje profitne marže, a istodobno su bila suočena s većom stopom bankrota i većom fluktuacijom radne snage.

Osim spomenutog istraživanja o budućnosti zaposlenosti (Frey i Osborne, 2013.) važno je spomenuti i istraživanje Acemoglu i Restrepo (2017.), koje istražuje utjecaj robota i računalne tehnologije na budućnost tržišta rada na osnovi podataka o povećanju upotrebe robota u razdoblju između 1990. i 2007. u SAD-u. S pomoću modela u kojem se roboti natječu protiv ljudi u obavljanju različitih poslova i zadataka pokazuju da uvođenje robota može smanjiti zaposlenost i nadnice ovisno o industriji. Stoga zaključuju da automatizacija, robotizacija i umjetna inteligencija imaju snažan negativan utjecaj na tržište rada. Prema njihovim procjenama uvođenje dodatnog robota na tisuću zaposlenika smanjuje stopu zaposlenosti za 0,18 – 0,34 postotna boda, a nadnice za 0,25 – 0,5 posto.

[3] C – prerađivačka industrija, D – opskrba električnom energijom, plinom, parom i klimatizacija, H – prijevoz i skladištenje, J – informacije i komunikacije te M – stručne, znanstvene i tehničke djelatnosti jesu djelatnosti koje najviše uvode napredne tehnologije I4.0.

Veža *et al*. (2018.) istražuju položaj hrvatskih proizvodnih poduzeća u odnosu na industriju 4.0, odnosno "može li poduzeće preživjeti na tržištu bez uzimanja strateških smjernica prema Industriji 4.0. do 2020. godine?". Prema provedenom je istraživanju industrijska zrelost hrvatskih poduzeća na vrlo niskoj razini (tek neznatno višoj od razine druge industrijske revolucije). Iskazana je i temeljna slabost, a to je nedovoljno praćenje tehnike zbog niske razine usavršavanja zaposlenika iz uzorka anketiranih poduzeća (rijetko više od pet dana godišnje). Dobiveni rezultati odgovaraju zaključku istraživanja Rolanda Bergera (prema Veža *et al*., 2018.), prema kojem Hrvatska ima vrlo nizak indeks spremnosti[4] za industriju 4.0 te spada u tzv. "oklijevajuću" skupinu (engl. *hesitators*), zajedno s Bugarskom, Poljskom, Portugalom, Estonijom, Španjolskom i Italijom. Takav zaključak proizlazi iz odnosa između udjela industrije u BDP-u te spremnosti na uvođenje industrije 4.0 europskih država, od kojih je slabiji rezultat od Hrvatske iskazala samo Bugarska.

Studija McKinseya (Novak *et al.*, 2018.) spominje digitalizaciju kao novi zamašnjak u razvoju zemalja Srednje i Istočne Europe (CEE), koje nazivaju tzv. digitalnim izazivačima (engl. *digital challengers)*. CEE jest jedno od najatraktivnijih mjesta za investiranje na globalnoj razini, što pruža priliku koju Hrvatska treba iskoristiti kako bi se smanjio jaz prema razvijenim zemljama zapadne Europe. Njihova atraktivnost proizlazi iz visoke matematičke pismenosti (gotovo jednaka kao i kod tzv. *front-runner* zemalja), velikog STEM[5] talenta te visokokvalitetne digitalne infrastrukture s izvrsnom pokrivenošću mrežom 4G. Regiju CEE nazivaju "živim digitalnim ekosustavom u nastajanju" i procjenjuju da bi digitalizacija mogla biti pokretač regije koji bi mogao doprinijeti s 200 milijarda eura dodatnog BDP-a do 2025. (8,3 milijarde eura, tj. približno 2000 eura BDP-a *per capita* za Hrvatsku, McKinsey, 2018.).

3. Prepoznavanje potencijala za I4.0 s pomoću strojnog učenja

Ovo istraživanje procjenjuje spremnost hrvatskih poduzeća za jačanje tehnološko-inovativnog potencijala, kao i prednosti i ograničenja te rizike koje sa sobom donosi četvrta industrijska revolucija. Analiza je zasnovana na procjeni potencijala za uvođenje tehnologija I4.0 na širem skupu hrvatskih poduzeća. Potencijal za I4.0 definira se kao sličnost poduzeća s poduzećima koja su autonomno identificirana kao korisnici tehnologije I4.0. U ovom dijelu opisuje se skup upotrijebljenih podataka i provedena metoda.

[4] Mjereno stupnjem proizvodne složenosti poslovnog procesa, automatizacije, inovativnosti i znanja (spremnosti radne snage)

[5] Prema engleskom terminu *science, technology, engineering and mathematics*

Prvi je izazov prepoznavanje poduzeća čije su poslovanje ili proizvod (usluga) vezani uz četvrtu industrijsku revoluciju (I4.0). U Hrvatskoj ne postoji jedinstvena sistematizirana evidencija korisnika visoke tehnologije nove generacije. Poduzeća koja pouzdano upotrebljavaju tehnologiju I4.0 identificirana su individualnom provjerom svakog subjekta s popisa poduzeća korisnika visokih tehnologija iz različitih izvora prema kriterijima opisanima u nastavku (Poglavlje 3.2. i Dodatak A., Tablica A.1.).

Potencijal, odnosno spremnost poduzeća za uvođenje I4.0 procijenjena je probabilistički primjenom klasifikacijskog algoritma nadziranoga strojnog učenja s binominalnom zavisnom varijablom. Na temelju modelske procjene vjerojatnosti klasificiraju se ostala promatrana poduzeća u skupinu I4.0 (vjerojatnost > 50%), što znači da su ona vrlo slična poduzećima koja su nedvojbeno identificirana kao korisnici ili proizvođači nekih od navedenih tehnologija četvrte industrijske revolucije (Dodatak A., Tablica A.1.) ili u skupinu tradicionalnih poduzeća (vjerojatnost <= 50%) ako to nije.

Nerijetko se uz nove tehnologije veže percepcija povišenog rizika, što otežava ili barem dodatno poskupljuje financiranje istraživačkih i razvojnih projekata. Ovaj rad pokazuje da ne postoji objektivno uporište za percepciju veće rizičnosti poduzeća I4.0, koja svoj razvojni put temelje na visokoj tehnologiji. Upravo suprotno, ulaganje u razvoj i nove tehnologije povećava njihovu konkurentnost na sve zahtjevnijim tržištima koja kvalitetu i pouzdanost postavljaju kao novi standard, ispred cijene.

3.1. Podaci

Analiza potencijala za uvođenje I4.0 promatra poduzeća iz pet djelatnosti koje obuhvaćaju C – prerađivačku industriju, D – opskrbu električnom energijom, plinom, parom i klimatizaciju, H – prijevoz i skladištenje, J – informacije i komunikacije te M – stručne, znanstvene i tehničke djelatnosti.

Uzorak poduzeća čine subjekti čija su godišnja financijska izvješća[6] javno objavljena za 2017. i 2012. godinu, čemu su, ovisno o dostupnosti, dodani i financijski pokazatelji i neke stavke iz bilance i računa dobiti i gubitka za 2008. godinu (neprobabilistički uzorak). Neprobabilistički uzorak čini oko 35% ukupnog broja poduzeća analiziranih djelatnosti, odnosno 88% aktive, 85% poslovnih prihoda i 78% ukupnog broja zaposlenih u navedenim granama djelatnosti.

Navedene kriterije zadovoljava ukupno 7147 poduzeća (Tablica 1.), od kojih je ekspertnom procjenom[7] prepoznato 58 da aktivno koristi ili nudi tehnologiju i usluge

[6] Izvor: baza Financijske agencije GFI-POD

[7] Ekspertna procjena upotrebe tehnologija I4.0 napravljena je na temelju dostupnih podataka iz različitih izvora (vidi Literaturu), uz dodatnu provjeru na internetskim stranicama analiziranih subjekata te je tako identificirano 110 poduzeća, a od kojih je 58 (Dodatak A., Tablica A.1.) zadržano i u konačnom neprobabilističkom podatkovnom skupu "7147".

prema kriterijima za I4.0. Pokazatelji i stavke iz bilance i RDG-a koji su testirani za uključivanje u model za procjenu potencijala uvođenja I4.0 opisani su u Dodatku u Tablici B.1. i Tablici B.2.

Tablica 1. Broj analiziranih subjekata prema različitim uzorcima

Vrsta uzorka	Broj analiziranih subjekata	Udio u neprobabilističkom uzorku
Trening-uzorak	512	7,16%
Testni uzorak	501	7,00%
Neprobabilistički uzorak	**7147**	**100%**

Tablica 2. Broj analiziranih subjekata prema različitim djelatnostima

Industrija	Broj analiziranih subjekata
C – prerađivačka industrija	2803
D – opskrba električnom energijom, plinom, parom i klimatizacija	103
H – prijevoz i skladištenje	747
J – informacije i komunikacije	989
M – stručne, znanstvene i tehničke djelatnosti	2505
UKUPNO	**7147**

Vidljivo je da je najveći broj poduzeća iz djelatnosti C – prerađivačka industrija i djelatnosti M – stručne, znanstvene i tehničke djelatnosti (Tablica 2.).

Tablica 3. Neprobabilistički uzorak prema veličini poduzeća

Veličina poduzeća	Broj analiziranih subjekata
1 (mala i mikropoduzeća)	6457
2 (srednja)	528
3 (velika)	162
UKUPNO	**7147**

3.2. Hipoteza i pretpostavke

Polazna je hipoteza da su poduzeća koja imaju slične financijske pokazatelje poslovanja kao i identificirani korisnici I4.0 na sličnoj razini tehnološke opremljenosti i organizacijskog ustroja, što omogućava prepoznavanje potencijalnih korisnika I4.0 u širem skupu poduzeća.

Budući da u Hrvatskoj zasada ne postoji sustavna evidencija korisnika tehnologije I4.0 (kao npr. Cerved u Italiji), prikupljeni podaci o visokotehnološkim poduzećima i korisnicima/proizvođačima tehnologija I4.0 pojedinačno su provjereni za svaki subjekt.

Kriterij za označavanje poduzeća kao nedvojbenoga korisnika I4.0 jest pronalaženje dokaza da poduzeće upotrebljava ili proizvodi/pruža proizvode ili usluge zasnovane na barem jednoj tehnologiji četvrte industrijske revolucije, a to su: "veliki podaci" i analize, roboti, simulacije, horizontalne i vertikalne integracije sustava, internet stvari, kibersigurnost, tehnologija oblaka, trodimenzionalni ispis ili proširena stvarnost. Popis tih poduzeća prikazan je u Dodatku A., Tablica A.1. Prepoznavanje ostalih potencijalnih korisnika tehnologije I4.0 oslanja se na sličnosti u strukturi financijskih izvješća i pokazatelja takvih poduzeća u odnosu na identificirana I4.0 poduzeća, poglavito udjelu nematerijalne imovine u dugotrajnoj te ulaganjima u istraživanje i razvoj, kao što je to primjerice primijenjeno i u istraživanju Cerved (2017.). Razlika u odnosu na navedeno istraživanje jest u tome što ti pokazatelji nisu odabrani isključivo ekspertnom procjenom, već su, uz druge pokazatelje, potvrđeni kao statistički signifikantni tako što u konačnom klasifikacijskom modelu njihove grane imaju najveću informacijsku dobit (engl. *information gain*) pri klasificiranju poduzeća u I4.0.

U tu svrhu upotrijebljen je binomni logistički (logit) klasifikacijski model izračunat s pomoću tehnike dubokoga strojnog učenja ekstremnog podizanja gradijenta (engl. *Extreme Gradient Boosting*, XGB) metodom nadziranog učenja (engl. *supervised learning*). XGB se pokazao kao superioran model u binomnoj logističkoj klasifikaciji također u području procjene rizika (Petropoulos *et al*., 2018.), i među ostalim algoritmima dubokog učenja i u odnosu na logističku regresiju. Njihovi rezultati testirani su empirijski, usporednom procjenom s pomoću logističke regresije, kojom su također postignuta nešto slabija diskriminatorna svojstva modela u odnosu na XGB.

Metoda XGB polazi od osnovnoga linearnog modela (Chen *et al.*, 2016.):

$$\hat{y}_i = \sum_j w_j x_{ij} \tag{1}$$

odnosno njegove logističke transformacije dane izrazom:

$$\Pr(Y = 1 \mid X) = \frac{1}{1 + e^{-\hat{y}_i}} \tag{2}$$

čiji se parametri

$$\theta = \{w_j \mid j = 1, ..., d\} \tag{3}$$

optimiraju tako da se minimizira pogreška na trening-uzorku, ali i na ostalim modelu "neviđenim" podacima:

$$Obj(\theta) = L(\theta) + \Omega(\theta) \tag{4}$$

U ciljnoj funkciji $Obj(\theta)$ $L(\theta)$ predstavlja funkciju minimizacije pogreške na trening--podacima, a $\Omega(\theta)$ regularizaciju, najčešće s pomoću L_2 euklidske norme kako bi se regresija "izgladila" i prilagodila "neviđenim" podacima. Primijenjeni je oblik ciljne funkcije binomna logistička funkcija (objective = "binary:logistic").

Za K stabala odlučivanja model poprima oblik

$$\hat{y}_i = \sum_{k=1}^{K} f_k(x_i) \tag{5}$$

te slično za bilo koje t-to stablo

$$\hat{y}_i^{(t)} = \sum_{k=1}^{t} f_k(x_i) \tag{6}$$

Funkcija gubitaka za binomnu logističku klasifikaciju poprima oblik

$$L = -\frac{1}{N}\sum_{i=1}^{N}\left(y_i \log(p_i) + (1-y_i)\log(1-p_i)\right) \tag{7}$$

gdje je y_i željena vrijednost, a p_i predviđena vrijednost. Regularizacijska funkcija za T broj listova u stablu definirana je oblikom

$$\Omega = \gamma T + \frac{\lambda}{2}\sum_{j=1}^{T} w_j^2 \tag{8}$$

gdje je γ minimalni stupanj smanjenja gubitka čije povećanje doprinosi konzervativnosti modela. XGB rabi algoritam gradijentnog spusta (engl. *gradient descent*) u minimizaciji ciljne funkcije i grananja stabala, pri čemu se upotrebljava predviđena vrijednost iz prethodnoga koraka, pojednostavnjeno zapisano:

$$y^{(t)} = y^{(t-1)} + \eta f_t(x_i) \tag{9}$$

gdje je η stopa učenja, koja smanjuje utjecaj svakoga novog stabla u iteraciji, a time i prenaučenost modela.

Budući da je vrlo mali broj poduzeća u cijelom uzorku identificiran kao I4.0,

uzorci za treniranje i testiranje modela napravljeni su slučajnim uzorkovanjem iz neprobabilističkog uzorka tako da su I4.0 poduzeća podijeljena u omjeru 60 : 40 u korist trening-uzorka, dok su preostala poduzeća kandidati odabrana slučajnim odabirom (Slika 1.).

Slika 1. Distribucija trening-uzorka

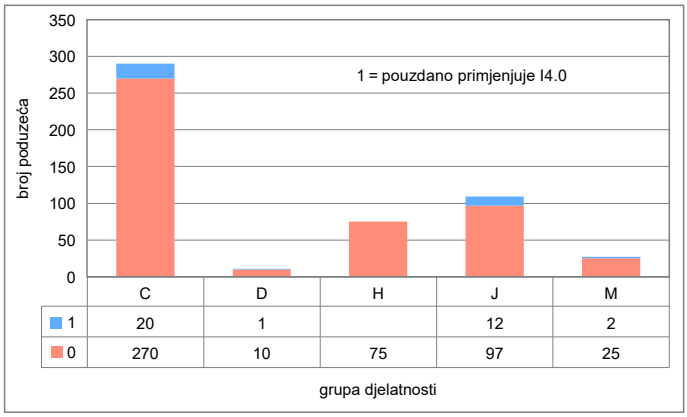

U Tablici 4. prikazana su poduzeća identificirana kao I4.0. Najveći udio među njima u trening-uzorku ima skupina malih poduzeća (44,7%), zatim velika poduzeća (31,6%) te potom srednja poduzeća (23,7%).

Tablica 4. Struktura trening-uzorka I4.0 po veličini poduzeća

Veličina poduzeća	Broj I4.0 poduzeća	Udio, %
1 – mala poduzeća	17	44,7%
2 – srednja poduzeća	9	23,7%
3 – velika poduzeća	12	31,6%
Ukupno trening-uzorak	**38**	**100,0%**

Testni uzorak odabran je tako da svojom strukturom po djelatnostima odgovara trening--uzorku (Slika 2.).

Slika 2. Distribucija testnog uzorka

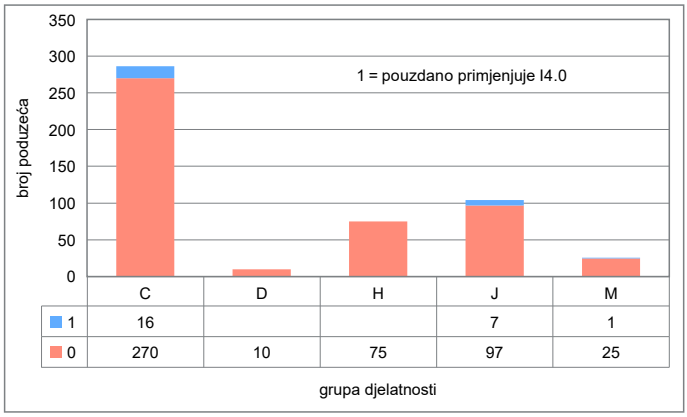

Tablica 5. Struktura testnog uzorka I4.0 po veličini poduzeća

Veličina poduzeća	Broj poduzeća s potencijalom	Udio, %
1 – mala poduzeća	14	43,8%
2 – srednja poduzeća	12	37,5%
3 – velika poduzeća	6	18,8%
Ukupno testni uzorak	**32**	**100,0%**

U Tablici 5. prikazan je broj subjekata s potencijalom za I4.0 u testnom uzorku, gdje je najveći broj malih poduzeća (43,8%), zatim srednjih poduzeća (37,5%) i velikih poduzeća (18,8%).

3.3. Model za procjenu potencijala primjene I4.0

Model za procjenu potencijala primjene tehnologija četvrte industrijske revolucije učen je na trening-uzorku, a provjeren s pomoću testnog uzorka. Kako bi se izbjegla prekomjerna prilagodba modela trening-uzorku (prenaučenost), primijenjena je iterativna metoda uzorkovanja iz neprobabilističkog uzorka za oba uzorka: trening--uzorak i testni uzorak, tzv. *boot-straping* metoda, kojom se iz početnog uzorka slučajnim odabirom kreiraju različiti uzorci, čime se ispituju performanse modela izvan uzorka (engl. *out-of-sample*). Postupak je ponavljan 20 puta pri čemu su izmjenjivana poduzeća koja ulaze u uzorke slučajnim odabirom i zadržana zadana distribucija uzoraka po grupama djelatnosti (Slika 1. i Slika 2.). Metodologija XGBoost rabi nekoliko parametara u procjeni modela (vidi poglavlje 3.2.). Primijenjena je binomna logistička ciljna funkcija (*objective = "binary:logistic"*), s obzirom na ciljnu zavisnu varijablu koja poprima samo dvije vrijednosti: 0 ili 1, a rezultat je klasifikacije vjerojatnost upotrebe tehnologija I4.0. Kao broj iteracija učenja odabran je 4 (*nrounds* = 4), a budući da je uzorak mali, mali je broj poduzeća koja zadovoljavaju kriterij zavisne varijable, kao i broj nezavisnih varijabla potencijalnih klasifikatora. Dubina učenja zbog istih je razloga zadržana na malim vrijednostima: 2 (*max.depth* = 2). Svaki par trening--testnih uzoraka uzet je za procjenu i provjeru diskriminatorne snage modela i njezine stabilnosti na promjenu uzorka za različite parametre gama (γ ... minimalni stupanj smanjenja gubitka; vidi jednadžbu (8)) i eta (η ... stopa učenja; vidi jednadžbu (9)) XGB klasifikacije.

Dobiveni su rezultati prikazani grafički (Slika 3.), pri čemu su kriteriji za odabir optimalnih parametara za procjenu modela maksimizacija diskriminatorne snage modela mjerena omjerom preciznosti (engl. *Accuracy Ratio*, AR ili GINI) i istodobno minimiziranje njegove standardne devijacije. Dobivene prosječne vrijednosti Ginijeva koeficijenta za 20 iteracija uz zadane kombinacije parametara gama i eta te pripadajuće standardne devijacije rangirane su prema optimizacijskim kriterijima (Tablica 6.). Prosječni Ginijevi koeficijenti rangirani su od najvećeg prema najmanjem (rang najvećeg = 1), a standardna devijacija od najmanje prema najvećoj (rang najmanje =

1). Ukupni je rang suma tih dvaju rangova, a najbolji (najmanji) rang jest optimum kombinacije parametara gama i eta.

Slika 3. Diskriminatorna snaga i stabilnost modela XGB na promjene parametara gama i eta

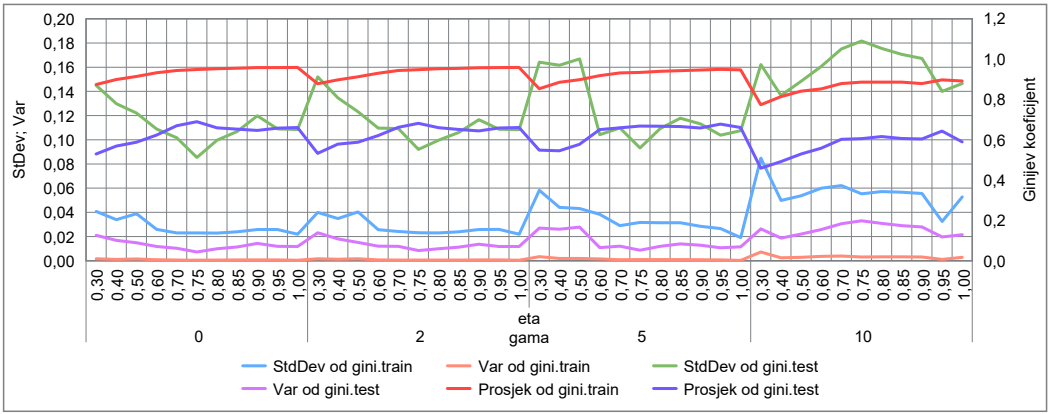

Optimalna kombinacija parametara gama i eta dobivena je za gama = 0 i eta = 0,75. Rezultirajući Ginijevi koeficijenti za trening-uzorak i testni uzorak uz optimalne parametre gama i eta u 20 provedenih iteracija prikazani su grafički (Slika 4.), gdje je vidljivo kretanje Ginijeva koeficijenta od vrijednosti oko 0,9 pa do 0,98 za trening--uzorke (prosjek 0,95) te između vrijednosti 0,55 i 0,81 (prosjek 0,69) za testne uzorke.

U provedenih 20 iteracija varijable koje imaju najvišu ukupnu informacijsku dobit[8] jesu: pripadnost visoko tehnološki intenzivnoj djelatnosti (Eurostatova klasifikacija)[9], udio izdataka za razvoj u dugotrajnoj imovini, relativna promjena udjela koncesija, patenata i licencija u ukupnoj dugotrajnoj imovini u razdoblju 2012. – 2017., udio izvoza u prihodima, relativna promjena udjela nematerijalne imovine u dugotrajnoj imovini u razdoblju 2012. – 2017., omjer tržišne i nominalne kapitalizacije, starost poduzeća, investicije u novu dugotrajnu imovinu po zaposlenom, dugotrajna

[8] Suma informacijske dobiti (engl. *information gain*) u 20 iteracija

[9] Stupanj tehnološkog intenziteta industrije određen je prema Organizaciji za ekonomsku suradnju i razvoj (OECD) i Eurostatovoj klasifikaciji istraživačko-razvojnog intenziteta pojedinih industrijskih grana na sljedeći način:

a) visoki intenzitet (HT): C21 – Proizvodnja osnovnih farmaceutskih proizvoda i farmaceutskih pripravaka, C26 – Proizvodnja računala te elektroničkih i optičkih proizvoda

b) srednje visoki intenzitet (MHT): C20 – Proizvodnja kemikalija i kemijskih proizvoda, C27 – Proizvodnja električne opreme, C28 – Proizvodnja strojeva i uređaja, C29 – Proizvodnja motornih vozila, prikolica i poluprikolica, C30 – Proizvodnja ostalih prijevoznih sredstava

c) srednje nizak intenzitet (MLT): C19, C22 – C25, C33 – proizvodnja koksa i rafiniranih naftnih proizvoda, proizvoda od gume, plastike, minerala i metala, popravak i instaliranje strojeva i opreme

d) nizak intenzitet (LT): C10 – C18, C31 – C32 – proizvodnja prehrambenih proizvoda, duhanskih proizvoda, pića, tekstilnih proizvoda i odjeće, proizvoda od kože, drva, papirna industrija, tiskanje i umnožavanje snimljenih medija, izrada namještaja i ostala prerađivačka industrija

Tablica 6. Rangiranje rezultata iteracija prema optimizacijskim kriterijima

	Trening-uzorak		Testni uzorak					
gama eta	Rang 1 (avg.gini)	Rang 2 (–Stdev)	Rang 3 (avg.gini)	Rang 4 (–Stdev)	Rang 5 (avg. gini)	Rang 6 (–Stdev)	Rang 5+6	Najbolji rang?
0	**0,959**	**0,02191**	**0,690**	**0,08533**	25	25	50	
0,3	11	10	11	11	47	34	81	
0,4	10	8	10	10	41	29	70	
0,5	9	9	9	9	37	26	63	
0,6	8	7	8	6	28	15	43	
0,7	7	2	2	3	4	6	10	
0,75	6	3	1	1	1	1	2	da
0,8	5	1	4	2	14	4	18	
0,85	4	4	6	4	18	10	28	
0,9	3	5	7	8	21	24	45	
0,95	2	6	5	7	17	16	33	
1	1	0	3	5	9	13	22	
2	**0,958**	**0,02198**	**0,682**	**0,09201**	26	27	53	
0,3	11	9	11	10	45	37	82	
0,4	10	8	10	9	38	31	69	
0,5	9	10	9	8	36	28	64	
0,6	8	5	8	6	29	19	48	
0,7	7	4	2	5	8	17	25	
0,75	6	2	1	0	2	2	4	
0,8	5	1	4	1	12	5	17	
0,85	4	3	6	2	19	9	28	
0,9	3	6	7	7	22	22	44	
0,95	2	7	5	4	16	14	30	
1	1	0	3	3	10	12	22	
5	**0,949**	**0,01919**	**0,677**	**0,09328**	24	30	54	
0,3	11	10	10	9	43	41	84	
0,4	10	9	11	8	44	39	83	
0,5	9	8	9	10	39	42	81	
0,6	8	7	8	2	20	8	28	
0,7	7	3	6	5	13	20	33	
0,75	6	6	2	0	5	3	8	
0,8	5	5	3	4	6	18	24	
0,85	4	4	4	7	7	23	30	
0,9	3	2	7	6	15	21	36	
0,95	1	1	1	1	3	7	10	
1	2	0	5	3	11	11	22	
10	**0,897**	**0,03252**	**0,643**	**0,13665**	40	44	84	
0,3	11	10	11	5	49	40	89	
0,4	10	1	10	0	48	32	80	
0,5	9	3	9	3	46	36	82	
0,6	8	8	8	4	42	38	80	
0,7	6	9	6	8	34	46	80	
0,75	4	4	4	10	32	48	80	
0,8	3	7	2	9	30	47	77	
0,85	5	6	3	7	31	45	76	
0,9	7	5	5	6	33	43	76	
0,95	1	0	1	1	23	33	56	
1	2	2	7	2	35	35	70	
	0,959	**0,01919**	**0,690**	**0,08533**				

Izvor: Obrada autora

Slika 4. Ginijevi koeficijenti trening-uzoraka i testnih uzoraka uz optimalne parametre gama i eta (XGB)

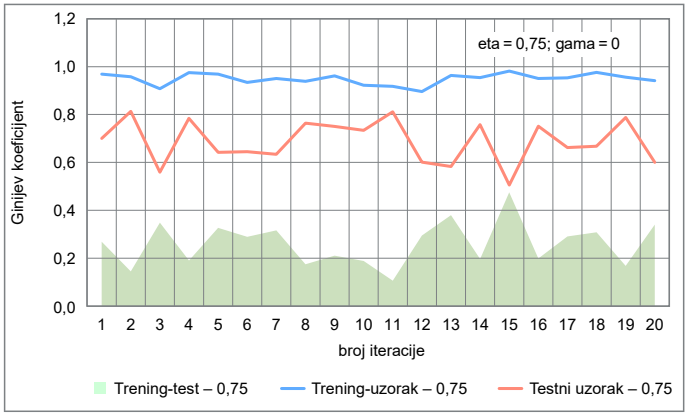

financijska imovina u ukupnoj aktivi, poslovni rashodi u prihodima i dr. (Slika 5.). Detaljan popis svih upotrijebljenih varijabla i pokazatelja vidi u Dodatku B. Većina je relevantnih klasifikacijskih varijabla strukturne prirode (omjeri u bilanci i računu dobiti i gubitka poput udjela izdataka za istraživanje i razvoj u dugotrajnoj imovini koji je u prosjeku oko 16% kod I4.0 poduzeća, a ispod 0,3% kod tradicionalnih promatrano na neprobabilističkom uzorku, vidi Tablicu 13.), što je očekivano s obzirom na visok udio imovine istraživačko-razvojnog i tehnološkog karaktera u ukupnoj imovini I4.0 poduzeća u odnosu na tradicionalna poduzeća.

Slika 5. Ukupna informacijska dobit pojedinih varijabla u 20 iteracija

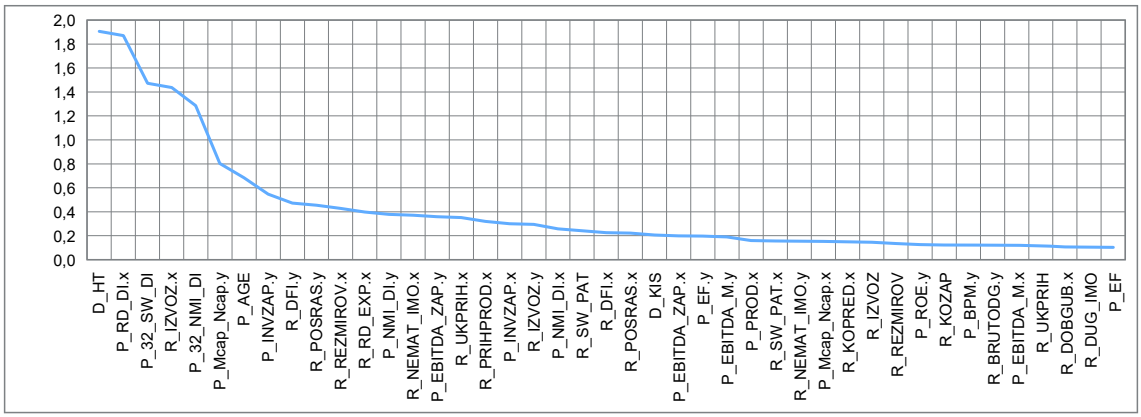

Napomena: Opis varijabla nalazi se u Dodatku B.

Za usporedbu, testiran je i model s pomoću logističke regresije na istim podacima (Dodatak C.). Dobiveni rezultati s obzirom na diskriminatornu snagu modela usporedivi su s XGB modelima, ali je prenaučenost (*overfitting*) mnogo veća, što je vidljivo u nižim vrijednostima Ginijeva koeficijenata testnog uzorka (Slika 6. i Slika 4.). Detalji o modelima koji uključuju logističku regresiju prikazani su u Dodatku C.

Slika 6. Diskriminatorna snaga logističkog modela

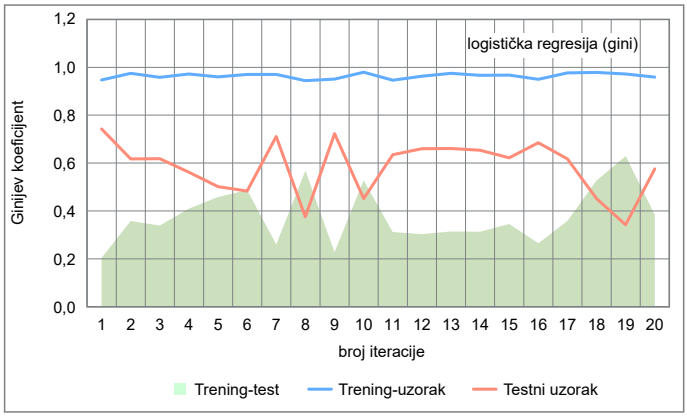

3.3.1. Procjena modela strojnim učenjem

Kao konačni model za procjenu potencijala primjene I4.0 odabran je model iz druge iteracije za gama = 0 i eta = 0,75, u kojoj je najmanja prenaučenost modela (najviša diskriminatorna snaga modela na testnom uzorku).

Slika 7. Informacijska dobit varijabla konačnog modela

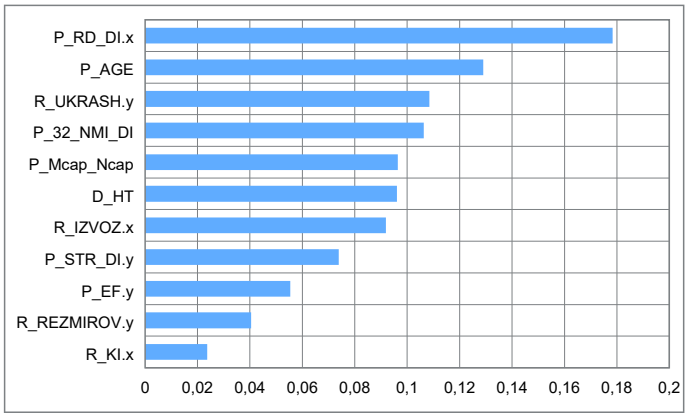

Napomena: Opis varijabla nalazi se u Dodatku B.

Procijenjeno XGB stablo odlučivanja prikazano je u Dodatku B (Slika B.1.), a varijable s najvišom informacijskom dobiti uključene u model jesu (od najveće informacijske dobiti prema manjoj, Slika 7.): udio izdataka za razvoj u dugotrajnoj imovini (pozitivni utjecaj), starost poduzeća (pozitivni utjecaj), omjer ukupnih rashoda i poslovnih prihoda (negativni utjecaj), relativna promjena udjela nematerijalne imovine u dugotrajnoj imovini u razdoblju 2012. – 2017. (pozitivni utjecaj), omjer tržišne i nominalne kapitalizacije (pozitivni utjecaj), pripadnost visoko tehnološki intenzivnoj djelatnosti (indikatorska varijabla, pozitivni utjecaj), udio izvoza u prihodima (pozitivni utjecaj), udio postrojenja i strojeva u dugotrajnoj imovini (pozitivni utjecaj), pokazatelj

efikasnosti: poslovni prihodi po zaposlenom (pozitivni utjecaj), udio rezerviranja za mirovine, otpremnine i slične obveze u aktivi (pozitivni utjecaj) i udio kratkotrajne imovine u aktivi (negativni utjecaj).

Visok udio izdataka za razvoj (dugotrajna nematerijalna imovina) u dugotrajnoj imovini posljedica su značajnih inicijalnih ulaganja u razvoj i kontinuiranog unapređivanja visokih tehnologija. Rezultati takvih izdataka za razvoj očekuju se u duljem razdoblju poslovanja poduzeća. Model prikazuje da subjekti s većim udjelom izdataka za razvoj u dugotrajnoj imovini imaju veću tendenciju prema industriji 4.0. Budući da su starije tehnološki intenzivne tvrtke prije počele ulagati i više ulagale u visoku tehnologiju, to ih, prema ovom modelu, izdvaja od tradicionalnih poduzeća. Radi se o većim poduzećima koja imaju postojane poslovne modele i znatnija ulaganja u tehnologiju. Poslovni prihodi nastaju iz temeljne djelatnosti poslovanja te prema modelu, ako poduzeća imaju ukupne rashode manje od poslovnih prihoda, prikazuje veću tendenciju industriji 4.0.

Poduzeća koja su u promatranom razdoblju između 2012. i 2017. povećala udio nematerijalne imovine u dugotrajnoj imovini imaju veću sklonost industriji 4.0 jer nematerijalna imovina, između ostalog, obuhvaća vrijednost patenata, softvera, licencija i različitih vrsta intelektualne imovine. Tržišnom kapitalizacijom smatra se tržišna vrijednost dionica poduzeća te je ona, ako je viša od nominalne kapitalizacije, pokazatelj da je tržište prepoznalo spomenuto poduzeće kao uspješno. Iskazivanje većeg izvoza posljedica je veće tržišne konkurentnosti i inovativnosti. Poslovni je prihod po zaposlenom kvalitetan pokazatelj učinkovitosti. Udio rezerviranja za mirovine, otpremnine i slične obveze u ukupnoj imovini u modelu ima pozitivan doprinos. Budući da je tijekom 2017. godine broj zaposlenika porastao u poduzećima s potencijalima za I4.0 (Tablica 8.), visok udio rezerviranja za mirovine, otpremnine i slične obveze upućuje na zaključak da poduzeća potencijali “pomlađuju” strukturu ljudskih potencijala.

Slika 8. Krivulja kumulativnog profila preciznosti (CAP) konačnog modela na trening-uzorku

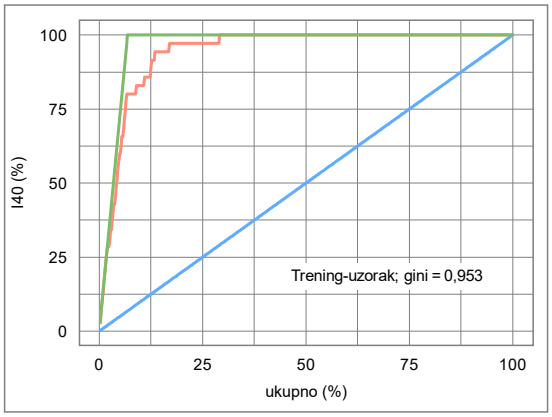

Slika 9. Krivulja kumulativnog profila preciznosti (CAP) konačnog modela na testnom uzorku

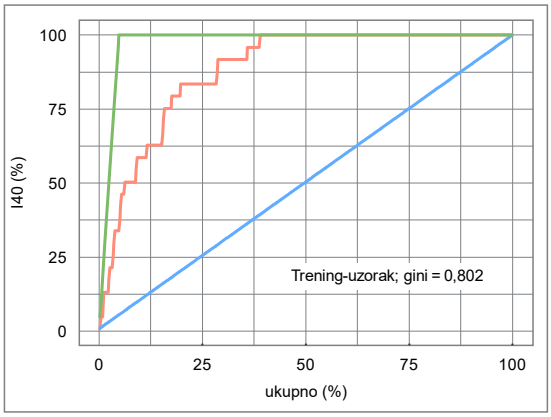

Diskriminatorna je snaga modela na trening-uzorku iznimna – Ginijev koeficijent iznosi 0,95 (Slika 8.), dok je na testnom uzorku neznatno niža (0,8; Slika 9.), a ujedno najviša dobivena u 20 iteracija.

Iznimno visoka diskriminatorna snaga modela na testnom uzorku, kao i na trening--uzorku potvrđuje da ne postoji značajna prekomjerna prilagodba podataka trening--uzorku, te se procjene dobivene modelom mogu smatrati nepristranima.

4. Analiza rezultata

Slika 10. prikazuje funkciju gustoće distribucije vjerojatnosti potencijala I4.0 na skupu analiziranih poduzeća definiranog kao vjerojatnost koju model pridružuje u klasifikaciji I4.0 poduzeća. Na slici je vidljiva najveća koncentracija poduzeća unutar prvih 20% vjerojatnosti, dok je iznad 50% vjerojatnosti gustoća distribucije vrlo mala, što upućuje na vrlo slabu spremnost za primjenu tehnologija I4.0 u Hrvatskoj. Od analiziranih 7147 poduzeća 141 poduzeće (uključujući 58 ekspertno identificiranih) klasificirano je u poduzeća koja su potencijal za I4.0, što čini 1,97% svih analiziranih subjekata.

Slika 10. Funkcija gustoće distribucije potencijala I4.0

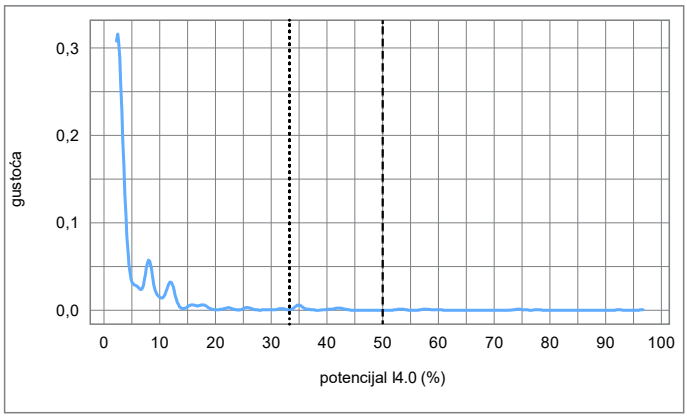

4.1. Analiza potencijala I4.0 na cijelom skupu (neprobabilistički uzorak)

Tablica 7. prikazuje potencijale industrije 4.0 koji uključuju ekspertno identificirane i modelom detektirane potencijale prema djelatnostima. Najveći udio po broju poduzeća u ukupnom potencijalu za I4.0 ima skupina djelatnosti C – prerađivačka industrija (44,7%), a zatim slijedi skupina djelatnosti J – informacije i komunikacije (42,6%). Znatno manji udio imaju djelatnosti skupine M – stručne, znanstvene i tehničke djelatnosti (9,9%) te H – prijevoz i skladištenje i D – opskrba električnom energijom, plinom, parom i klimatizacija (1,4% svaka).

Tablica 7. Broj i udio poduzeća s potencijalom za I4.0 prema industriji – neprobabilistički uzorak

Djelatnost	Broj	Udio
C – prerađivačka industrija	**63**	**44,7%**
Distribucija i prijenos električne energije te proizvodnja uređaja za distribuciju i kontrolu električne energije	4	2,8%
Ostala proizvodnja (alata, elektromotora...)	38	27,0%
Proizvodnja farmaceutskih pripravaka	3	2,1%
Proizvodnja instrumenata i aparata za mjerenje, ispitivanje i navigaciju	2	1,4%
Proizvodnja komunikacijske opreme	3	2,1%
Računalne djelatnosti, obrada podataka, usluge poslužitelja i djelatnosti povezane s njima	11	7,8%
Usluge (izdavanje ostalog softvera, ostale informacijske uslužne djelatnosti, upravljačke djelatnosti...)	2	1,4%
D – opskrba električnom energijom, plinom, parom i klimatizacija	**2**	**1,4%**
Distribucija i prijenos električne energije te proizvodnja uređaja za distribuciju i kontrolu električne energije	2	1,4%
H – prijevoz i skladištenje	**2**	**1,4%**
Usluge (izdavanje ostalog softvera, ostale informacijske uslužne djelatnosti, upravljačke djelatnosti...)	2	1,4%
J – informacije i komunikacije	**60**	**42,6%**
Djelatnosti žičane i bežične telekomunikacije	3	2,1%
Računalne djelatnosti, obrada podataka, usluge poslužitelja i djelatnosti povezane s njima	53	37,6%
Usluge (izdavanje ostalog softvera, ostale informacijske uslužne djelatnosti, upravljačke djelatnosti...)	4	2,8%
M – stručne, znanstvene i tehničke djelatnosti	**14**	**9,9%**
Inženjerstvo i s njim povezano tehničko savjetovanje	4	2,8%
Ostalo istraživanje i eksperimentalni razvoj u prirodnim, tehničkim i tehnološkim znanostima	5	3,5%
Usluge (izdavanje ostalog softvera, ostale informacijske uslužne djelatnosti, upravljačke djelatnosti...)	5	3,5%
Ukupno	**141**	**100,0%**

Slika 11. Distribucija potencijala I4.0 prema razredima djelatnosti

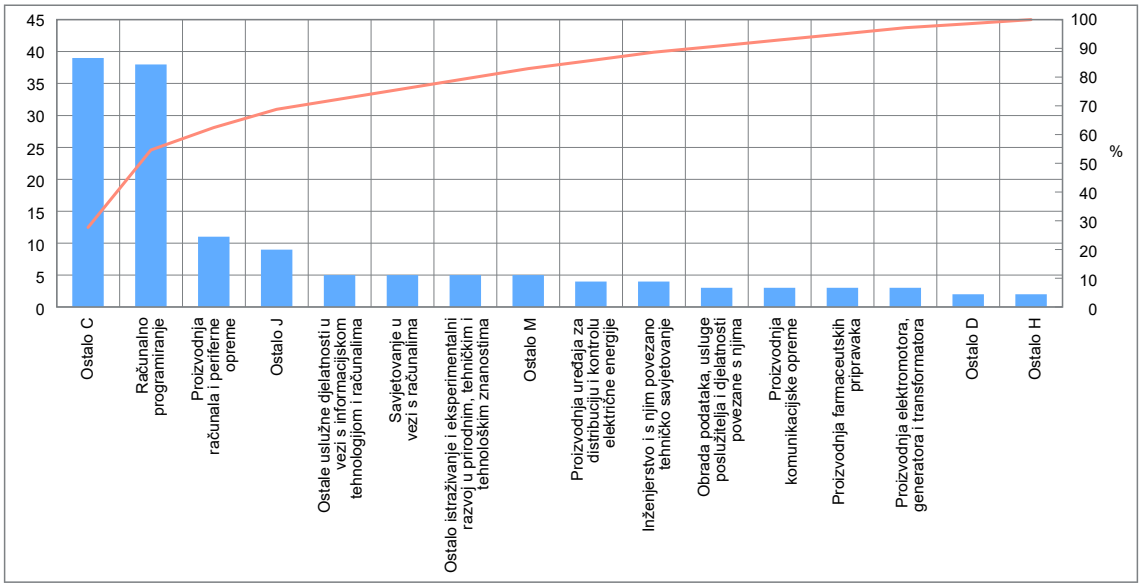

Od poduzeća koja prema ovom istraživanju tvore potencijal u hrvatskoj industriji 4.0, najviše ih se nalazi u djelatnosti J-6201 računalno programiranje (38), C-2620 proizvodnja računala i periferne opreme (11), J-6202 savjetovanje u vezi s računalima, J-6209 ostale uslužne djelatnosti u vezi s informacijskom tehnologijom i računalima te M-7219 ostalo istraživanje i eksperimentalni razvoj u prirodnim, tehničkim i tehnološkim znanostima (po pet subjekata u svakoj kategoriji, Slika 11.).

Slika 12. Potencijali I4.0 prema veličini poduzeća

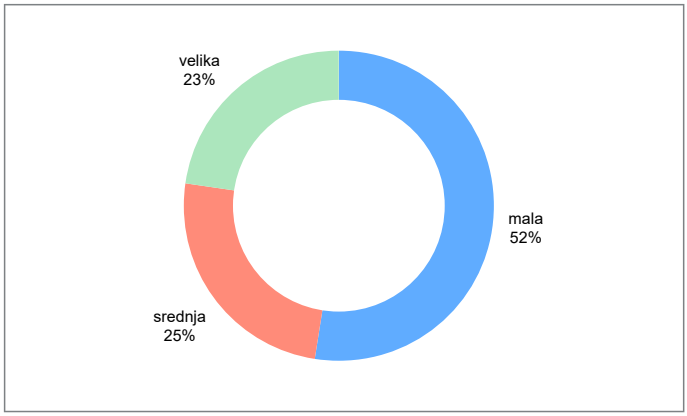

Izvor: Fina (obrada autora)

Slika 12. prikazuje označene i modelom detektirane potencijale prema udjelu veličine poduzeća. Najveći udio u potencijalima skupine imaju mala poduzeća (52%), dok su srednja (25%) i velika poduzeća (23%) zastupljena u približnom udjelu.

Međutim, iako broj poduzeća s potencijalom za I4.0 nije velik, ona čine oko 27% aktive neprobabilističkog uzorka (oko 24% populacije analiziranih djelatnosti) te oko 26% poslovnih prihoda (22% populacije analiziranih djelatnosti), Tablica 8.

Najveći broj subjekata (48 poduzeća) nalazi se u skupini od 11 do 50 zaposlenika. Najmanji se broj nalazi u skupini s manje od 10 zaposlenika (16), a što se može obrazložiti teže dostupnim izvorima financiranja za razvojne/investicijske projekte zbog povišenog rizika i manjkom ljudskih resursa za provođenje složenih, visokotehnoloških projekata.

Tablica 9. sažeto prikazuje broj poduzeća za analizirane uzorke prema grupi djelatnosti i prema veličini poduzeća. Potencijal za I4.0 definiran je za modelski procijenjene vjerojatnosti više od ili jednake 50%, dok se za trening-uzorak i testni uzorak potencijal odnosi na poduzeća za koja je nedvojbeno identificirano da upotrebljavaju neku od tehnologija četvrte industrijske revolucije. Broj poduzeća za koja se procjenjuje da imaju potencijal za I4.0 relativno je malen u odnosu na ukupan broj poduzeća analiziranih djelatnosti, no sva su ona visokog stupnja automatizacije proizvodnih procesa. Tehnološki najrazvijenije zemlje primjenjuju različite mehanizme potpora

Tablica 8. Potencijali industrije 4.0

Potencijal/veličina	Broj zaposl. u 2016.	Ukupno zaposl. 2017.	Broj tvrtki	Udio u aktivi uzorka	Udio u aktivi	Udio u posl. prihod. uzorka	Udio u posl. prihod.
Tradicionalna	227.256	231.710	7.006	72,7%	100,0%	74,1%	100,0%
MALA	**76.223**	**78.470**	**6.383**	**12,5%**	**17,2%**	**17,3%**	**23,35%**
<=10	14.491	14.401	4.393	3,8%	5,2%	4,1%	5,59%
11 – 50	39.913	41.196	1.740	7,4%	10,1%	10,2%	13,78%
51 – 250	19.885	20.809	244	1,4%	1,9%	2,9%	3,89%
>250	1.934	2.064	6	0,0%	0,0%	0,1%	0,09%
SREDNJA	**65.075**	**66.456**	**493**	**15,3%**	**21,0%**	**20,7%**	**27,98%**
<=10	63	42	7	0,5%	0,6%	1,1%	1,46%
11 – 50	2.124	1.938	57	2,8%	3,9%	2,4%	3,29%
51 – 250	46.730	47.269	384	10,6%	14,6%	14,8%	20,00%
>250	16.158	17.207	45	1,4%	1,9%	2,4%	3,23%
VELIKA	**85.958**	**86.784**	**130**	**45,0%**	**61,8%**	**36,0%**	**48,67%**
<=10	8	8	1	0,6%	0,9%	0,1%	0,16%
11 – 50	164	134	5	3,2%	4,4%	3,6%	4,83%
51 – 250	2.640	2.720	16	2,5%	3,5%	3,5%	4,71%
>250	83.146	83.922	108	38,6%	53,1%	28,9%	38,97%
Potencijal I4.0	**47.696**	**48.372**	**141**	**27,3%**	**100,0%**	**25,9%**	**100,0%**
MALA	**1.958**	**2.132**	**74**	**0,4%**	**1,5%**	**0,5%**	**2,09%**
<=10	96	92	16	0,0%	0,1%	0,0%	0,10%
11 – 50	1.121	1.203	45	0,3%	1,2%	0,4%	1,37%
51 – 250	741	837	13	0,1%	0,3%	0,2%	0,62%
SREDNJA	**5.146**	**5.489**	**35**	**1,6%**	**5,7%**	**1,5%**	**5,72%**
11 – 50	110	120	3	0,1%	0,2%	0,1%	0,31%
51 – 250	2.884	3.157	27	1,3%	4,9%	1,1%	4,13%
>250	2.152	2.212	5	0,2%	0,6%	0,3%	1,27%
VELIKA	**40.592**	**40.751**	**32**	**25,3%**	**92,8%**	**23,9%**	**92,19%**
51 – 250	736	786	4	0,7%	2,4%	0,7%	2,88%
>250	39.856	39.965	28	24,6%	90,4%	23,2%	89,32%
Ukupno	**274.952**	**280.082**	**7.147**	**100,0%**		**100,0%**	
Udio grupa djelatnosti C, D, H, J, M u populaciji		**78,2%**	**34,9%**	**88,0%**		**84,5%**	

Izvor: Fina (obrada autora)

za uvođenje tehnologija I4.0 poput poreznih olakšica, i pri uvođenju tehnološke infrastrukture i za investiranje u edukaciju i usavršavanje zaposlenika (Francuska), visokih stopa (hiper)amortizacije te posebnih fondova za financiranje investicijskih i razvojnih projekata (Italija, Njemačka, Finska). Osim direktnih financijskih potpora razvijene zemlje na različite načine dodatno omogućuju i potiču pokretanje i ulaganja u I4.0. Potiče se izgradnja i razvoj infrastrukture i prilagođavaju se regulativni okviri kako

Tablica 9. Usporedni prikaz uzoraka i potencijala

Vrsta industrije / veličina poduzeća	Neprob. uzorak	Neprob. uzorak – potencijali	Testni uzorak	Testni uzorak – potencijali	Trening--uzorak	Trening--uzorak – potencijali
C – prerađivačka industrija	**2803**	**63**	**286**	**19**	**290**	**21**
1 – mala poduzeća	2334	21	240	7	237	8
2 – srednja poduzeća	364	18	29	6	38	5
3 – velika poduzeća	105	24	19	6	15	8
D – opskrba električnom energijom, plinom, parom i klimatizacija	**103**	**2**	**10**	**0**	**11**	**1**
1 – mala poduzeća	79	0	7	0	9	0
2 – srednja poduzeća	14	0	0	0	1	0
3 – velika poduzeća	10	2	3	0	1	1
H – prijevoz i skladištenje	**747**	**2**	**75**	**1**	**75**	**0**
1 – mala poduzeća	662	2	68	1	66	0
2 – srednja poduzeća	63	0	5	0	5	0
3 – velika poduzeća	22	0	2	0	4	0
J – informacije i komunikacije	**989**	**60**	**104**	**11**	**109**	**14**
1 – mala poduzeća	934	43	96	6	99	8
2 – srednja poduzeća	38	13	6	5	6	3
3 – velika poduzeća	17	4	2	0	4	3
M – stručne, znanstvene i tehničke djelatnosti	**2505**	**14**	**26**	**1**	**27**	**2**
1 – mala poduzeća	2448	8	24	0	26	1
2 – srednja poduzeća	49	4	2	1	1	1
3 – velika poduzeća	8	2	0	0	0	0
Ukupno	**7147**	**141**	**501**	**32**	**512**	**38**

Izvor: Fina (obrada autora)

bi se omogućilo pokretanje razvojnih tvrtki (engl. *start-up*), jednak pristup raspoloživim podacima te upotreba visoke tehnologije I4.0 poput autonomnih vozila, dronova i robota. Primjer takve zemlje jest Estonija, a sličnu praksu provode i Švedska, Norveška i Finska.

4.2. Poslovne performanse i rizičnost I4.0 poduzeća

Glavni su razlikovni pokazatelji potencijala I4.0 i tradicionalnih poduzeća na analiziranom uzorku strukturne prirode, poput udjela nematerijalne imovine ili poslovnih postrojenja i strojeva u dugotrajnoj imovini, ulaganja u istraživanja i razvoj, udjela kratkotrajne imovine u ukupnoj imovini i sl. Osim strukturnih razlika u financijskim izvješćima poduzeća I4.0 potencijala imaju znatno bolje pokazatelje poslovanja, od kojih su pojedini uključeni i u sam model jer imaju značajan utjecaj

u diskriminaciji poduzeća pri procjeni potencijala (Slika 6.). Osjetno bolje poslovne performanse najizraženije su u pokazateljima investiranja, troškovne efikasnosti, tehničke opremljenosti i tržišne konkurentnosti, dok pokazatelji profitabilnosti, iako u prosjeku viši, nisu signifikantno bolji.

Unatoč višem kapitalu po zaposleniku (graničnoj stopi tehničke supstitucije), prosjek nije signifikantno različit u odnosu na poduzeća tradicionalne tehničke opremljenosti, što pokazuje jednofaktorska analiza varijance ANOVA (Slika 13. i Tablica 10.). Prirast broja zaposlenih tijekom 2017. godine i u razdoblju 2012. – 2017. nešto je veći od prirasta broja zaposlenih u tradicionalnoj industriji, ali nesignifikantno, dok su plaće zaposlenika u poduzećima potencijala I4.0 signifikantno više (Slika 14. i Tablica 11.).

Slika 13. Distribucije granične stope tehničke supstitucije (MRTS)

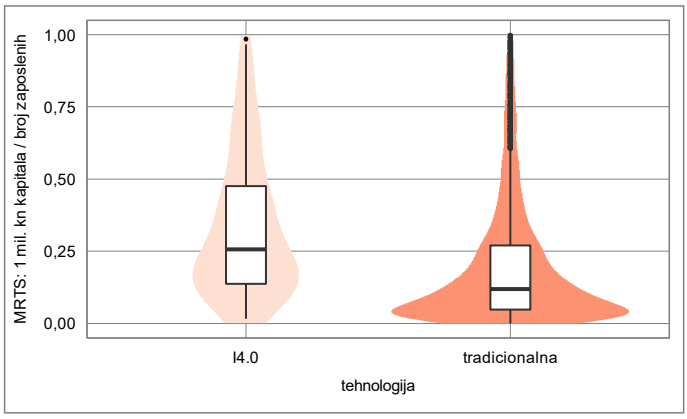

Tablica 10. ANOVA granične stope tehničke supstitucije

Anova: Single Factor

SUMMARY

Groups	Count	Sum	Average	Variance
I4.0	141	95,65396	0,678397	1,624471
Tradicionalna	7006	2738,178	0,390833	31,6031

ANOVA

Source of Variation	SS	df	MS	F	P-value	F crit
Between Groups	11,42966	1	11,42966	0,368512	0,543836	3,842761
Within Groups	221607,1	7145	31,01569			
Total	**221618,5**	**7146**				

Iako primjena visokih tehnologija pokazuje negativne učinke na zaposlenost (tzv. Keynesova "tehnološka nezaposlenost"), ovakvo gledište zanemaruje druge, pozitivne učinke tehnologije, kao što su kreiranje novih (drugačijih, složenijih) radnih mjesta, poticanje inovativnosti i produktivnosti te druge koristi, npr. u zdravstvu, maloprodaji, sigurnosti (Bughin *et al.*, 2017.).

Slika 14. Distribucije prosječnih godišnjih troškova osoblja po zaposlenom

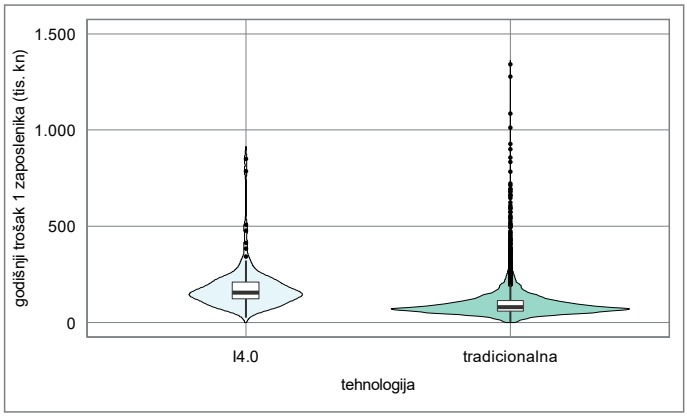

Tablica 11. ANOVA prosječnog troška zaposlenika

Anova: Single Factor

SUMMARY

Groups	Count	Sum	Average	Variance
Tradicionalna	7006	685.248.603	97.809	6.998.915.742
I4.0	141	24.938.859	176.871	12.066.478.002

ANOVA

Source of Variation	SS	df	MS	F	P-value	F crit
Between Groups	863.986.034.781	1	863.986.034.781	121,7188578	0,00000	3,84276064
Within Groups	50.716.711.694.672	7145	7.098.210.174			
Total	**51.580.697.729.453**	**7146**				

Poduzeća s potencijalom za I4.0 konkurentnija su i na inozemnom tržištu, zbog čega je njihov udio izvoznih prihoda u poslovnim prihodima značajno viši nego kod tradicionalnih poduzeća (Slika 15. i Tablica 12.).

Slika 15. Distribucije udjela izvoza u poslovnim prihodima

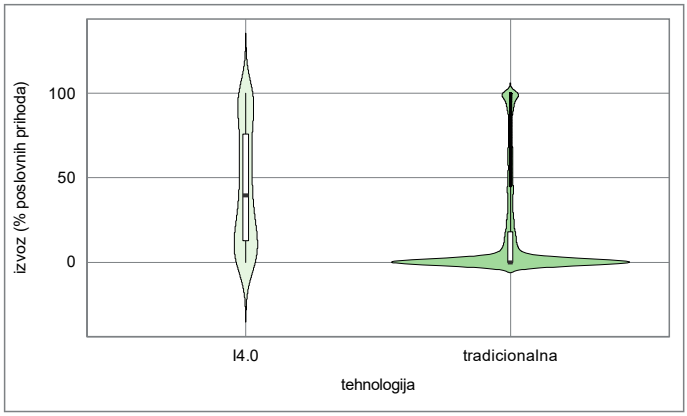

Tablica 12. ANOVA udjela izvoza u poslovnim prihodima

Anova: Single Factor

SUMMARY

Groups	Count	Sum	Average	Variance
Tradicionalna	7006	1195,753	0,17067556	0,0918911
I4.0	141	62,9177885	0,44622545	0,12434291

ANOVA

Source of Variation	SS	df	MS	F	P-value	F crit
Between Groups	10,4946011	1	10,4946011	113,422087	0,00000	3,84276064
Within Groups	661,105142	7145	0,09252696			
Total	**671,599743**	**7146**				

Poduzeća s potencijalom za I4.0 značajno više nego tradicionalna poduzeća ulažu i u istraživanje i razvoj novih tehnologija u odnosu na ostalu dugotrajnu imovinu.

Slika 16. Distribucije udjela istraživanja i razvoja u dugotrajnoj imovini

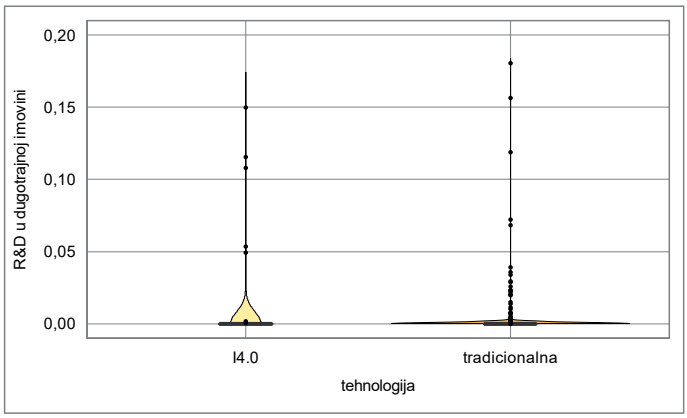

Tablica 13. ANOVA udjela ulaganja u istraživanje i razvoj u dugotrajnoj imovini

Anova: Single Factor

SUMMARY

Groups	Count	Sum	Average	Variance
Tradicionalna	6355	22,670588	0,00357	0,00221
I4.0	141	22,4446999	0,15918	0,07486

ANOVA

Source of Variation	SS	df	MS	F	P-value	F crit
Between Groups	3,34034285	1	3,34034285	885,29853	0,00000	3,84289117
Within Groups	24,5026798	6494	0,00377313			
Total	**27,8430227**	**6495**				

Sve prednosti i pozitivne učinke koje donosi razvoj, investiranje i upotreba visokih tehnologija prema kriterijima I4.0, odražavaju se i na povećanje vrijednosti takvih poduzeća na tržištu kapitala (promatrano za poduzeća koja kotiraju na službenim burzama) u odnosu na nominalnu vrijednost dionica, što je također jedan od pokazatelja koji se kvalificirao u model. Učinkovitost, konkurentnost i razvojnu strategiju prepoznaju investitori na tržištu vrijednosnica, a to pozitivno utječe na njihovu cijenu.

Rizičnost I4.0 poduzeća značajno je niža od rizičnosti tradicionalnih poduzeća (na razini signifikantnosti od 1%; Tablica 14.) jer od promatranih oko 7000 poduzeća ni jedno I4.0 poduzeće nije imalo zabilježeno kašnjenje u plaćanju obveza duže od 90 dana (*default*, tj. rejting D prema Fini), za razliku od tradicionalnih (Slika 17. i Slika 18.).

Slika 17. Distribucija vjerojatnosti zastoja u plaćanju (PD)
Probability of default

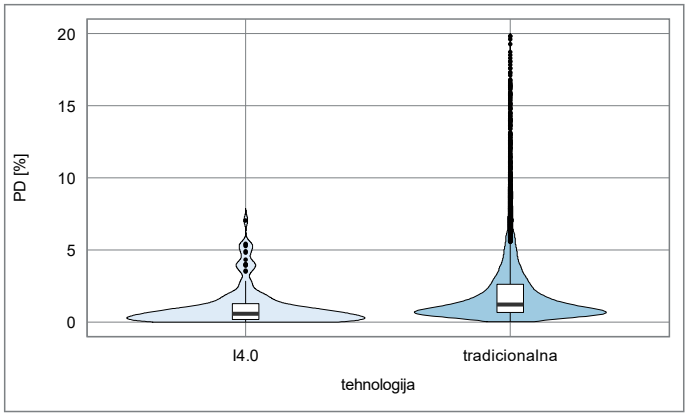

Tablica 14. ANOVA vjerojatnosti zastoja u plaćanju
Anova: Single Factor

SUMMARY

Groups	Count	Sum	Average	Variance
I4.0	139	1,45472593	0,01046565	0,00017906
Tradicionalna	6994	185,875407	0,02657641	0,00283621

ANOVA

Source of Variation	SS	df	MS	F	P-value	F crit
Between Groups	0,03537529	1	0,03537529	12,7030478	0,00036745	3,84276319
Within Groups	19,8583201	7131	0,00278479			
Total	**19,8936954**	**7132**				

Distribucije poduzeća I4.0 i tradicionalnih poduzeća po Fininim razredima rejtinga (Fina, 2019.) prikazana je na slici (Slika 18.), gdje je vidljiva povećana proporcija broja I4.0 poduzeća u boljim razredima, posebno u razredu 1, dok ni jedno nije svrstano u razrede lošije od 10, pa tako ni u D (*default*).

Slika 18. Distribucija proporcija poduzeća po razredima rejtinga[10]

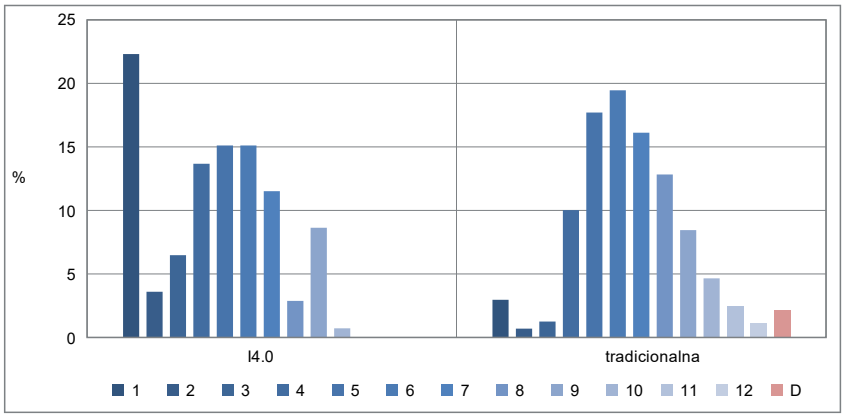

Napomena: "D" označava rejting za poduzeća u zastoju plaćanja (*default*).

Izvor: Fina (obrada autora)

Ulaganja poduzeća u istraživanje, razvoj i upotrebu novih tehnologija četvrte industrijske generacije pokazuje da ne postoji objektivno uporište za percepciju poduzeća I4.0 koja svoj razvojni put temelje na visokoj tehnologiji kao visokorizičnih pothvata ni ulaganja povišenog rizika. Upravo suprotno, ulaganje u razvoj i primjenu novih tehnologija otvara takvim poduzećima nova tržišta, povećava konkurentnost njihovim proizvodima i uslugama, podiže razinu znanja te u dugom roku osigurava stabilnost poslovanja i bolju profitabilnost i učinkovitost.

[10] Finini razredi rejtinga i pripadajući rasponi vjerojatnosti zastoja u plaćanju (*defaulta*)

Rejting	PD min.	PD maks.
1	0,00%	0,09%
2	0,09%	0,19%
3	0,19%	0,31%
4	0,31%	0,51%
5	0,51%	0,82%
6	0,82%	1,33%
7	1,33%	2,14%
8	2,14%	3,46%
9	3,46%	5,59%
10	5,59%	9,04%
11	9,04%	14,60%
12	14,60%	99,99%
D	100,00%	100,00%

5. Zaključak i implikacije rezultata za ekonomsku politiku

Industriju 4.0 čini devet tehnologija[11] te, ovisno o njihovoj upotrebi, možemo zaključiti je li određeno poduzeće na putu prema ostvarenju koncepta I4.0. Motivacije za primjenu tehnologije I4.0 mogu biti raznovrsne, od povećanja efikasnosti i produktivnosti poduzeća, smanjenja troškova poslovanja, povećanja profitabilnosti u dugom roku, do tržišnog pozicioniranja, postizanja viših kvalitativnih norma i sl. Bilance takvih uspješnih poduzeća pokazuju razlike u strukturi imovine i pokazateljima poslovanja prema tradicionalnim poduzećima. Financijski sektor također mora biti spreman financirati razvoj industrije 4.0.

Polazna je hipoteza u ovom radu da poduzeća koja upotrebljavaju tehnologije I4.0 imaju sličnu strukturu bilance i pokazatelje poslovanja, što omogućava prepoznavanje potencijalnih korisnika I4.0, odnosno procjenu vjerojatnosti da poduzeće već primjenjuje ili je u fazi uvođenja tehnologija I4.0. Upotrijebljen je binomni logistički (logit) klasifikacijski model izračunat tehnikom dubokoga strojnog učenja *Extreme Gradient Boosting* (XGBoost) metodologijom nadziranog učenja (engl. *supervised learning*). Od analiziranih 7147 poduzeća identificirano je 141 poduzeće s potencijalom za I4.0 (1,97% analiziranih subjekata) s oko 27% aktive neprobabilističkog uzorka (oko 24% populacije analiziranih djelatnosti) te oko 26% poslovnih prihoda (22% populacije analiziranih djelatnosti), dakle dominantno veliki poslovni subjekti.

Glavni su razlikovni pokazatelji potencijala I4.0 poduzeća u odnosu na tradicionalna poduzeća strukturne prirode, poput udjela nematerijalne imovine ili poslovnih postrojenja i strojeva u dugotrajnoj imovini, ulaganja u istraživanja i razvoj, proporcije kratkotrajne imovine u ukupnoj i sl. Značajno bolje poslovne performanse najizraženije su u pokazateljima investiranja, troškovne efikasnosti, tehničke opremljenosti i tržišne konkurentnosti, dok su u ovoj, još uvijek ranoj fazi uvođenja tehnologija I4.0, pokazatelji profitabilnosti u prosjeku viši, no razlika nije statistički značajna. Iako poduzeća s potencijalom za I4.0 imaju veći omjer kapitala i rada (kapitalnu opremljenost rada), trošak njihova zaposlenika gotovo je dva puta veći nego u tradicionalnoj industriji. Poduzeća s potencijalom za I4.0 konkurentnija su i na inozemnom tržištu, zbog čega je njihov udio izvoznih prihoda u poslovnim prihodima značajno viši od tradicionalnih. Povećanje ekonomičnosti, učinkovitosti i profitabilnosti zahtijeva znatno veće investiranje u istraživanje i razvoj novih tehnologija, ali zbog vremena za povrat uloženoga razlike prema tradicionalnim poduzećima u ovoj fazi razvoja nisu značajne. Također, djelatnost igra važnu ulogu te se najviše poduzeća s potencijalom I4.0 nalazi u skupini vezanoj uz računala, računalne djelatnosti, obradu podataka i sl. zbog lakše dostupnosti tehnologije I4.0 u IT segmentu, odnosno činjenice da se već bave određenim segmentom I4.0.

[11] Prema kriteriju BCG-a

Rezultati upućuju na zaključak da je rizičnost I4.0 poduzeća značajno niža od rizičnosti tradicionalnih poduzeća, jer od promatranih 7147 poduzeća ni jedno I4.0 poduzeće nije imalo zabilježen zastoj u plaćanju obveza duži od 90 dana, za razliku od tradicionalnih. I4.0 poduzeća više su koncentrirana u boljim razredima rejtinga[12], posebno u razredu 1, a ni jedno nije svrstano u razrede rejtinga lošije od 10, pa tako ni u D (*default*). Ulaganje u razvoj i primjenu novih tehnologija otvara hrvatskim I4.0 poduzećima nova tržišta, povećava konkurentnost njihovih proizvoda i usluga, podiže razinu znanja te u dugom roku osigurava stabilnost poslovanja, bolju profitabilnost i učinkovitost, što ih čini i manje rizičnima te stabilnijima od tradicionalnih poduzeća. To je također dokazano empirijski i odražava se u dobivenoj strukturi modela: modelom identificirane varijable koje karateriziraju poduzeća I4.0 upućuju na veću razinu ulaganja u razvoj (viši udio izdataka za razvoj u dugotrajnoj imovini), veću relativnu promjena udjela nematerijalne imovine u dugotrajnoj imovini u razdoblju 2012. – 2017. te viši udio postrojenja i strojeva u dugotrajnoj imovini, nego kod tradicionalnih poduzeća. Modelom je isto tako dokazano da I4.0 poduzeća karakteriziraju varijable koje pokazuju pozitivan utjecaj I4.0 na njihovu konkurentnost i efikasnost: omjer tržišne i nominalne kapitalizacije, udio izvoza u prihodima i poslovni prihodi po zaposlenom te manji omjer ukupnih rashoda i poslovnih prihoda (troškovno su efikasnija).

Dobiveni rezultati pokazuju da se s povećanim ulaganjima u istraživanje i razvoj, nabavu novih i modernizaciju postojećih postrojenja i opreme te ulaganjima u softverska rješenja za autonomno upravljanje strojevima ili umjetnu inteligenciju može očekivati rast efikasnosti rada (veći prihodi po zaposleniku). Jačanje konkurentnosti, izvoza i pozitivne investicijske klime vrlo je važno za malo i otvoreno europsko gospodarstvo koje ima priliku i kapacitete za razvoj.

S obzirom na navedene prednosti I4.0 poduzeća poželjno je da država potiče ulaganja u istraživanja i razvoj, tj. tehnologije I4.0, pri čemu se može primijeniti pristup kojim se koriste razvijene zemlje. To su osnivanje posebnih fondova za financiranje investicija i razvojnih projekata kao u Italiji, Njemačkoj i Finskoj, prilagodba regulativnih okvira (poticanje pokretanja razvojnih tvrtki, reguliranje uporabe tehnologije I4.0 poput autonomnih vozila, dronova i robota), promjena i prilagodba edukativnog sustava novim potrebnim radnim vještinama te poticanje primjene novih tehnologija. Velik dio populacije za nekoliko će godina raditi na poslovima koji danas još ne postoje. Kako bi se iskoristio potencijal hrvatskih poduzeća, potrebno je stvoriti poticajne uvjete za razvoj i rast poduzeća čija je djelatnost vezana uz industriju 4.0, bez obzira na to je li riječ o djelatnosti koja u svojoj proizvodnji rabi I4.0 ili proizvodi proizvode i usluge za industriju 4.0. Kao što ovo istraživanje pokazuje, poduzeća četvrte industrijske revolucije kvalitetna su poduzeća koja, uključivanjem u ovaj globalni trend razvoja, imaju potencijala za poboljšanje rasta i razvoja cijeloga gospodarstva, a to je moguće ako se poveća i potakne ulaganje u razvoj takvih poduzeća.

[12] Finin rejting, vidi bilješku 10.

Dodatak A.

Tablica A.1. Popis identificiranih tehnologija I4.0 u hrvatskim poduzećima

R. br.	ID	Proizvodi elemente I4.0	Upotrebljava elemente I4.0	Sjedište	Primijenjena tehnologija I4.0
1	I001	1		Osijek	Pametni strojevi, automatizirane proizvodne linije ili robotske ruke
2	I002	1		Zagreb	Visokoautomatizirani procesi proizvodnje
3	I003	1		Alaginci	Uporaba pametnih strojeva i robota u proizvodnji
4	I004		1	Orahovica	Upravljano računalom, roboti u proizvodnji
5	I005	1		Rijeka	Visokoautomatizirana proizvodnja, u drugoj fazi projekta izdvajanje automatskog skladišta
6	I006	1		Rugvica	Visok stupanj automatizacije proizvodnih procesa
7	I007		1	Vodnjan	Pružatelj usluge mobilnih komunikacija u oblaku (*cloud*) za poslovne korisnike
8	I008		1	Zagreb	Farmaceutska industrija
9	I009	1		Čakovec	Softverska rješenja za upravljanje odnosima s korisnicima (CRM) za farmaceutsku industriju
10	I010	1		Velika Gorica	Priprema se razvojno-investicijski ciklus vrijedan više milijuna eura, ubrzano ide prema konceptu tzv. industrije 4.0.
11	I011		1	Zagreb	BI, *Big Data*
12	I012	1		Zadar	Inovativni je izvoznik u području visokobrzinske tehnologije i robotske automatike. Pripada samom vrhu svjetske proizvodnje sofisticiranih motora, a njihovi se proizvodi rabe u automobilskoj industriji, najviše u Njemačkoj, ali i na tržištu od SAD-a do Koreje. U vrijeme krize proširili su poslovanje na industrijsku i robotsku automatizaciju.
13	I013		1	Zadar	Roboti u industriji stakla
14	I014	1		Samobor	Cjelokupni *know-how* u ovom sektoru rezultat je vlastitog istraživanja i razvoja, a gotovo sve se proizvodi u vlastitim visokoautomatiziranim i robotiziranim pogonima.
15	I015		1	Zagreb	Roboti u proizvodnji i restauraciji opreme za zrakoplove
16	I016	1		Zagreb	U svjetskom vrhu u inspekciji te proizvodnji dijelova i robota za nuklearne elektrane
17	I017		1	Zagreb	Sustavi oblaka, vertikalna integracija, IoT
18	I018	1		Bakar	Automatizirana proizvodnja s pomoću robota
19	I019	1		Osijek	Visokoautomatizirana proizvodnja
20	I020	1		Zagreb	Visokoautomatizirane linije; integracija sustava upravljanja
21	I021		1	Sveta Nedelja	Računalne simulacije u projektiranju i dizajnu
22	I022	1		Hum na Sutli	U proizvodnji, primjerice, primjenjuju zavarivanje robotom
23	I023	1		Zagreb	Horizontalna i vertikalna integracija sustava
24	I024	1		Sesvete	Inteligentno umreženi sustavi za komprimirani zrak u iznimno fleksibilnim proizvodnim okružjima kakva donosi idustrija 4.0; IoT
25	I025	1		Pustodol Začretski	Visoka tehnologija, nova proizvodna hala sa strojevima najsuvremenije tehnologije

R. br.	ID	Proizvodi elemente I4.0	Upotrebljava elemente I4.0	Sjedište	Primijenjena tehnologija I4.0
26	I026	1		Zagreb	Industrijska automatizacija, postavljena prva superbrza samoobnavljajuća mreža u Hrvatskoj kao pilot-projekt. Prvi put da je u Europi postavljena ovakva mreža na decentraliziranom sustavu s komunikacijskim protokolom preko bežične komunikacije, gdje se komunikacija odvija u stvarnom vremenu (*real time*). Ova je tehnologija prvi korak prema potpuno autonomnim sustavima s umjetnom inteligencijom u okviru *Smart Grid* tehnologija.
27	I027	1		Zagreb	Optimirana proizvodnja automatskih vrata i uvodi proces industrije 4.0 u svoju tvornicu u Zusmarshausenu (DE).
28	I028	1		Solin	3D ispis; 3D digitalizacija odnosno 3D skeniranje, 3D digitalna baza podataka iz koje se vrlo brzo može započeti s dizajnom ili redizajnom proizvoda. *Rapidprototyping* ili 3D *printing* tehnika je s pomoću koje se u nekoliko sati virtualni CAD dizajn pretvara u fizički model. Uređaj za 3D *printing* čita podatke iz 3D modela, slažući ih u mikronske *layere* koji se, ovisno o vrsti uređaja, spajaju u kompaktan proizvod.
29	I029		1	Osijek	Robotički tim; u pilot-projektima njihove će robote početi upotrebljavati neka domaća poduzeća.
30	I030		1	Rijeka	Edukativni *hexapod* robot, sustav na temelju kojeg svatko, ponajprije učenici, mogu samostalno napraviti i programirati *hexapod* robota.
31	I031		1	Zagreb	Umjetna inteligencija i strojno učenje u identifikaciji i prepoznavanju teksta
32	I032	1		Osijek	Proizvodnja opreme za dronove
33	I033	1		Kutina	Privatno i sigurno okružje računalnog oblaka osigurava maksimalnu zaštitu i privatnost podataka. Integracija IoT-a u poljoprivredi za centralno upravljanje svim nasadima i usjevima unutar tvrtke
34	I034	1		Zagreb	IoT – internet stvari
35	I035		1	Zagreb	Alati računalstva u oblaku za mikrofinanciranje
36	I036		1	Zagreb	IoT – internet stvari
37	I037	1		Zagreb	Prvi hrvatski proizvođač inteligentnih senzora za industriju 4.0
38	I038	1		Zagreb	Platforma za računalstvo u oblaku s geopodacima
39	I039		1	Zagreb	*Data science*, *machine learning* – strojno učenje, IoT – internet stvari
40	I040		1	Zagreb	Pohrana podataka, sigurnost informacija, analitika, računalstvo u oblaku samo su neke od usluga
41	I041	1		Zagreb	Razvoj prve nacionalne IoT mreže te povezivanje i poticanje tvrtki i pojedinaca da se uključe u razvoj rješenja koja rade na tehnologiji Sigfox.
42	I042		1	Zagreb	Primjena UI-ja u kontroli kvalitete proizvoda na proizvodnoj liniji, 3D pisači, virtualne simulacije
43	I043		1	Zagreb	Usluga razvoja i ugradnje robotskih sustava, u sklopu postojećih ili novih proizvodnih linija. Cjelokupni sustavi robotske paletizacije/depaletizacije te bilo koji drugi oblik robotske manipulacije
44	I044	1		Zagreb	Spoj digitalizacije, automatizacije i umjetne inteligencije
45	I045		1	Zagreb	Bogato iskustvo u različitim područjima implementacije rješenja za analitiku velikih podataka
46	I046		1	Solin	IoT – internet stvari
47	I047		1	Zagreb	Primjenjuje računalstvo u oblaku

Dodatak A.

R. br.	ID	Proizvodi elemente I4.0	Upotrebljava elemente I4.0	Sjedište	Primijenjena tehnologija I4.0
48	I048	1		Karlovac	Razvoj kompleksnih AI & Analytics rješenja za njemačkog proizvođača automobila
49	I049		1	Zagreb	Digitalizacija poslovanja (implementacijom IT rješenja, bilo da se radi o *hosting* infrastrukturi ili rješenjima s pomoću računalstva u oblaku)
50	I050	1		Zagreb	Posluje u sklopu visokotehnološke tvrtke; proizvodnja modularnih podatkovnih centara za svjetsko tržište (računalstvo u oblaku)
51	I051	1		Zagreb	Tehnologija koja čini izniman potencijal u izgradnji visoko upravljivog i automatiziranog IT sustava koji se tako svojim karakteristikama približio onome što se danas popularno naziva *Private Cloud*
52	I052	1		Zagreb	Jedan od najvećih projekata privatnog oblaka u regiji, primjenjuju naprednu kognitivnu analitiku u različitim poslovnim segmentima – brzo otkrivanje korelacija među podacima. U tehnološkom smislu razmatraju mogućnosti primjene tehnologije IoT (*Internet of Things*) u proizvodnji i prodajnom kanalu te strojnog učenja u upravljanju investicijama u marketingu; prate razvoj tehnologija *blockchaina* i umjetne inteligencije (AI).
53	I053	1		Zagreb	Vodeća uloga u oblikovanju trenda industrije 4.0; član inicijative njemačke vlade "I4.0", nudi cjelovita rješenja za automatizaciju, od oblaka preko upravljačke tehnologije, IoT prolaza, senzora i tehnologije pokretača.
54	I054	1		Zagreb	Umrežavanje i integracija "pametne proizvodnje" (*Industry 4.0*)
55	I055	1		Karlovac	Matična kompanija ima jednu od najvećih instaliranih baza u svjetskoj industriji robotike.
56	I056		1	Zagreb	Tehnologija u stvarnom vremenu (*real time*), na putu prema potpuno autonomnim sustavima s umjetnom inteligencijom (AI)
57	I057		1	Zagreb	Automatizacija i robotizacija proizvodnje, pametne tvornice u oblacima – *clouds*, trodimenzionalni inženjering i vizualizacija, *smart wiring*, potpuno automatizirana, brza i precizna strojna obrada upravljačkih ploča i kompletnih proizvoda. Proizvodnja upravljačkih ploča – također, one se upotrebljavaju u vodećim tehnologijama. Uvođenje sveobuhvatnih projektantskih softvera koji velik broj svakodnevnih zadataka u projektiranju i proizvodnji mogu automatizirati, osiguravajući razinu kvalitete i mogućnost brze prilagodbe inženjerskim izmjenama koja će se automatski odraziti i na konačni proizvod.
58	I058	1		Zagreb	Tvrtka specijalizirana za upotrebu umjetne inteligencije i njezinu primjenu u obradi podataka u robotici, dronovima i bespilotnim letjelicama.

Izvor: Obrada autora

Dodatak B.

Tablica B.1. Popis nezavisnih varijabla iz financijskih izvješća i zavisna varijabla

Naziv varijable	Opis	Naziv relativne varijable	U odnosu na
DUG_IMO	DUGOTRAJNA IMOVINA (AOP 003+010+020+031+036)	R_DUG_IMO	Ukupnu aktivu (TOTAKT)
NEMAT_IMO	NEMATERIJALNA IMOVINA (AOP 004 do 009)	R_NEMAT_IMO	Ukupnu aktivu (TOTAKT)
RD_EXP	Izdaci za razvoj	R_RD_EXP	Ukupnu aktivu (TOTAKT)
SW_PAT	Koncesije, patenti, licencije, robne i uslužne marke, softver i ostala prava	R_SW_PAT	Ukupnu aktivu (TOTAKT)
STROJEVI	Postrojenja i oprema	R_STROJEVI	Ukupnu aktivu (TOTAKT)
ALATI	Alati, pogonski inventar i transportna imovina	R_ALATI	Ukupnu aktivu (TOTAKT)
DFI	Dugotrajna financijska imovina	R_DFI	Ukupnu aktivu (TOTAKT)
DTPOT	Dugotrajna potraživanja	R_DTPOT	Ukupnu aktivu (TOTAKT)
DTPOTKRE	Potraživanja po osnovi prodaje na kredit	R_DTPOTKRE	Ukupnu aktivu (TOTAKT)
KI	Kratkotrajna imovina	R_KI	Ukupnu aktivu (TOTAKT)
ZAL	Zalihe	R_ZAL	Ukupnu aktivu (TOTAKT)
KTPOT	Kratkotrajna potraživanja	R_KTPOT	Ukupnu aktivu (TOTAKT)
KTPOTKUP	Od toga: potraživanja od kupaca	R_KTPOTKUP	Ukupnu aktivu (TOTAKT)
KTFI	Kratkotrajna financijska imovina	R_KTFI	Ukupnu aktivu (TOTAKT)
NOVAC	Novac	R_NOVAC	Ukupnu aktivu (TOTAKT)
TOTAKT	AKTIVA		
KAPREZ	Kapital i rezerve	R_KAPREZ	Ukupnu aktivu (TOTAKT)
REZMIROV	Rezerviranja za mirovine, otpremnine i slične obveze	R_REZMIROV	Ukupnu aktivu (TOTAKT)
DUGOBV	DUGOROČNE OBVEZE (084 do 092)	R_DUGOBV	Ukupnu aktivu (TOTAKT)
DOFI	Dugoročne obveze prema financijskim institucijama	R_DOFI	Ukupnu aktivu (TOTAKT)
DOPRED	Obveze za predujmove	R_DOPRED	Ukupnu aktivu (TOTAKT)
DODOB	Obveze prema dobavljačima	R_DODOB	Ukupnu aktivu (TOTAKT)
DOVP	Dugoročne obveze po izdanim vrijednosnim papirima	R_DOVP	Ukupnu aktivu (TOTAKT)
KO	Kratkoročne obveze	R_KO	Ukupnu aktivu (TOTAKT)
KOFI	Kratkoročne obveze prema financijskim institucijama	R_KOFI	Ukupnu aktivu (TOTAKT)
KOPRED	Obveze za predujmove	R_KOPRED	Ukupnu aktivu (TOTAKT)
KODOB	Obveze prema dobavljačima	R_KODOB	Ukupnu aktivu (TOTAKT)
KOVP	Obveze po vrijednosnim papirima	R_KOVP	Ukupnu aktivu (TOTAKT)
KOZAP	Kratkoročne obveze prema zaposlenima	R_KOZAP	Ukupnu aktivu (TOTAKT)
TOTPAS	PASIVA		
PP	Poslovni prihodi		
PRIHPROD	Prihodi od prodaje	R_PRIHPROD	Poslovne prihode (PP)
POSRAS	Poslovni rashodi	R_POSRAS	Poslovne prihode (PP)
MATTR	Materijalni troškovi (117 do 119)	R_MATTR	Poslovne prihode (PP)
TRSIROV	Troškovi sirovina i materijala	R_TRSIROV	Poslovne prihode (PP)
TRPRODROB	Troškovi prodane robe	R_TRPRODROB	Poslovne prihode (PP)
TRZAP	Troškovi zaposlenih	R_TRZAP	Poslovne prihode (PP)

Naziv varijable	Opis	Naziv relativne varijable	U odnosu na
NETOPL	Neto plaće i nadnice	R_NETOPL	Poslovne prihode (PP)
AMORT	Amortizacija	R_AMORT	Poslovne prihode (PP)
VUDI	VU dugotrajne imovine (osim financijske imovine)	R_VUDI	Poslovne prihode (PP)
VUKI	VU kratkotrajne imovine (osim financijske imovine)	R_VUKI	Poslovne prihode (PP)
UKPRIH	UKUPNI PRIHODI	R_UKPRIH	Poslovne prihode (PP)
UKRASH	UKUPNI RASHODI	R_UKRASH	Poslovne prihode (PP)
BRUTODG	DOBIT ILI GUBITAK PRIJE OPOREZIVANJA (146-147)	R_BRUTODG	Poslovne prihode (PP)
DOBGUB	DOBIT ILI GUBITAK RAZDOBLJA (148-151)	R_DOBGUB	Poslovne prihode (PP)
SUBV	Prihodi od dotacija, državne potpore i subvencija	R_SUBV	Poslovne prihode (PP)
KAPPROD	Kapitalizirana proizvodnja za vlastite potrebe	R_KAPPROD	Poslovne prihode (PP)
IZVOZ	Prihodi od prodaje u inozemstvu	R_IZVOZ	Poslovne prihode (PP)
INVDI	Investicije u novu dugotrajnu imovinu	R_INVDI	Poslovne prihode (PP)
ZAPOSL_SATITK	Broj zaposlenih na temelju sati rada u tekućem razdoblju		
ZAPOSL_SATIPR	Broj zaposlenih na temelju sati rada u prethodnom razdoblju		
Mcap	Tržišna kapitalizacija		
Ncap	Nazivna vrijednost kapitalizacije		
i40	**Oznaka da poduzeće primjenjuje (ili proizvodi) tehnologiju četvrte industrijske revolucije (zavisna varijabla modela; izvor: web)**		
D_HT	Poduzeće u djelatnosti visokog tehnološkog intenziteta		
D_MHT	Poduzeće u djelatnosti srednje visokog tehnološkog intenziteta		
D_MLT	Poduzeće u djelatnosti srednje niskog tehnološkog intenziteta		
D_KIS	Poduzeće u djelatnosti visokog intenziteta znanja		

Tablica B.2. Popis pokazatelja

Oznaka pokazatelja	Naziv pokazatelja	Brojnik	Nazivnik
P_EBITDA_ZAP	EBITDA po zaposlenom	(PP – POSRAS + AMORT)	ZAPOSL_SATITK
P_NMI_DI	Udio nematerijalne imovine u dugotrajnoj imovini	(NEMAT_IMO)	DUG_IMO
P_RD_DI	Udio izdataka za razvoj u dugotrajnoj imovini	(RD_EXP)	DUG_IMO
P_SW_DI	Udio koncesija, patenata, licencija... u ukupnoj dugotrajnoj imovini	(SW_PAT)	DUG_IMO
P_STR_DI	Udio postrojenja i strojeva u dugotrajnoj imovini	(STROJEVI)	DUG_IMO
P_AL_DI	Udio alata, pogonskog inventara i transportne imovine u dugotrajnoj imovini	(ALATI)	DUG_IMO
P_EBITDA_M	EBITDA marža	(PP – POSRAS + AMORT)	PP
P_INVEST	Udio amortizacije u dugotrajnoj imovini	(AMORT)	DUG_IMO
P_PROD	Udio troškova zaposlenih u poslovnim prihodima	(TRZAP)	PP
P_ROE	Povrat na kapital (ROE)	(DOBGUB)	KAPREZ
P_EBITDA_EQ	Povrat EBITDA na kapital	(PP – POSRAS + AMORT)	KAPREZ
P_BPM	Bruto marža profita	(BRUTODG)	UKPRIH

Oznaka pokazatelja	Naziv pokazatelja	Brojnik	Nazivnik
P_EF	Efikasnost (poslovni prihodi po zaposlenom)	(PP)	ZAPOSL_SATITK
P_POKR	Stupanj pokrića I	(KAPREZ)	DUG_IMO
P_SUBV_PP	Udio prihoda od državnih subvencija i potpora u poslovnim prihodima	(SUBV)	PP
P_EKON	Ekonomičnost	(UKPRIH)	UKRASH
P_DFI	Udio dugoročnog financiranja	(DUGOBV)	(TOTPAS – KAPREZ)
P_INVZAP	Investicije u novu dugotrajnu imovinu po zaposlenom	(INVDI)	ZAPOSL_SATITK
P_Mcap_Ncap	Omjer tržišne i nominalne kapitalizacije	(Mcap)	
P_AGE	Starost tvrtke		
P_32_NMI_DI	Relativna promjena indikatora P_NMI_DI u razdoblju 2012. – 2017.	($P_NMI_DI_{2017}$ – $P_NMI_DI_{2012}$)	$P_NMI_DI_{2012}$
P_32_RD_DI	Relativna promjena indikatora P_RD_DI u razdoblju 2012. – 2017.	($P_RD_DI_{2017}$ – $P_RD_DI_{2012}$)	$P_RD_DI_{2013}$
P_32_SW_DI	Relativna promjena indikatora P_SW_DI u razdoblju 2012. – 2017.	($P_SW_DI_{2017}$ – $P_SW_DI_{2012}$)	$P_SW_DI_{2014}$
P_32_STR_DI	Relativna promjena indikatora P_STR_DI u razdoblju 2012. – 2017.	($P_STR_DI_{2017}$ – $P_STR_DI_{2012}$)	$P_STR_DI_{2015}$
P_32_AL_DI	Relativna promjena indikatora P_AL_DI u razdoblju 2012. – 2017.	($P_AL_DI_{2017}$ – $P_AL_DI_{2012}$)	$P_AL_DI_{2016}$
P_32_EBITDA_ZAP	Relativna promjena indikatora P_EBITDA_ZAP u razdoblju 2012. – 2017.	($P_EBITDA_ZAP_{2017}$ – $P_EBITDA_ZAP_{2012}$)	$P_EBITDA_ZAP_{2017}$

Slika B.1. Stablo modela XGBoost

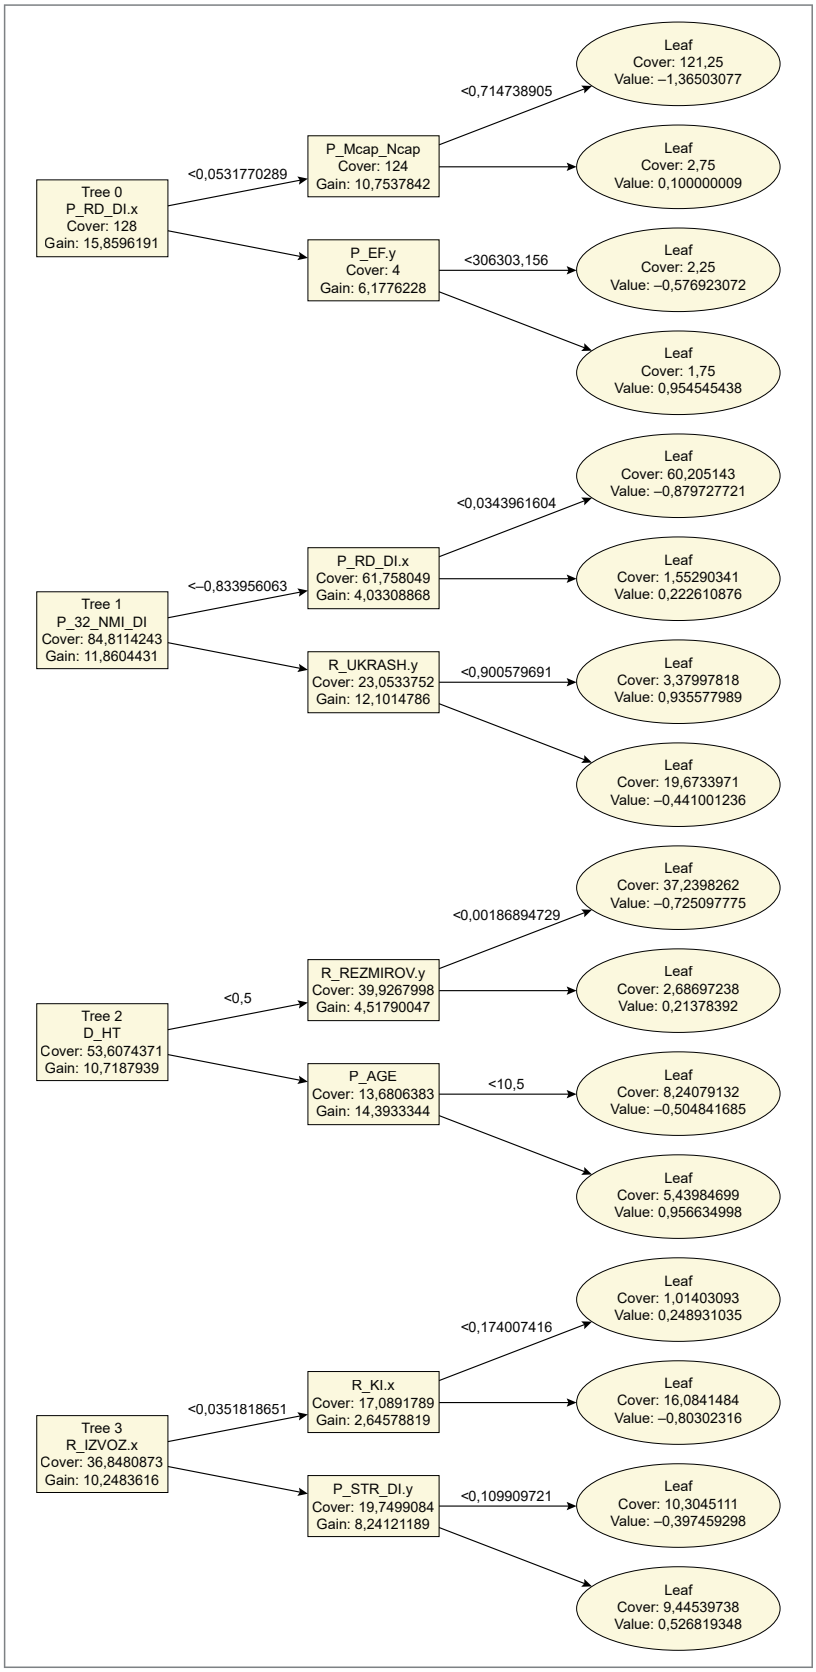

Dodatak C.

O strojnom učenju

Strojno učenje i pristupi zasnovani na podacima postaju sve značajniji u posljednje vrijeme i pronalaze primjenu u mnogim područjima: upravljanju i automatizaciji procesa, računalnim znanostima, sigurnosti (prepoznavanje uzoraka), klasifikaciji e-pošte, detekciji prijevara, pronalaženju anomalija, prepoznavanju govora, predviđanjima i simulacijama procesa (u financijama, zdravstvu, transportu) te mnogim drugim područjima. Dva su ključna čimbenika o kojima ovisi uspješna primjena strojnog učenja: upotreba efikasnih statističkih modela koji otkrivaju složene ovisnosti među različitim podacima i prilagodljivi sustavi učenja koji uče iz velikih skupova podataka. Sustavi strojnog učenja mogu biti nadzirani i nenadzirani. Nadzirani sustavi strojnog učenja uče tako što ulazni podaci za učenje sadržavaju ciljnu vrijednost varijable, pri čemu su podaci oblika (ulaz, izlaz) = ($\boldsymbol{x}$, y). Cilj je strojnog učenja pronalaženje funkcionalne veze f između ulaznih podataka $\boldsymbol{x}$ i ciljne vrijednosti y: $y = f(\boldsymbol{x})$. Kada je y kontinuirana varijabla, prikladnija je upotreba regresije, a kada je y diskretna varijabla, efikasniji je neki od klasifikacijskih algoritama.

Postoji više metoda strojnog učenja koje se primjenjuju u praksi (stablo odluke, slučajna šuma, neuronska mreža, K-najbližih susjeda, ansambl stabla odluke, strojevi s potpornim vektorima, podizanje gradijenta...), među kojima se u posljednje vrijeme svojom prediktivnošću značajnije ističe ekstremno podizanje gradijenta (engl. *eXtreme Gradient Boosting,* XGB), vidi Petropoulos *et al.* (2018.) i Chen *et al.* (2016.). Osnova metodologije XGB počiva na algoritmu podizanja stabla odluke koji slijednim učenjem gradi nova stabla odluke učeći na pogreškama prethodnog stabla, čime se postiže veća brzina algoritma (manji broj iteracija) i skalabilnost koja omogućava manje procesorske i memorijske zahtjeve i na velikim podacima.

XGB rabi gradijentni spust pri optimizaciji. Gradijentni spust uključuje teorem da funkcija $f(x)$ u točki ekstrema (minimuma) ima gradijent $\nabla f(x) = 0$, dok u ostalim točkama vrijednost gradijenta $\nabla f(x)$ odgovara smjeru porasta funkcije. Krenuvši od neke početno odabrane točke x, minimum funkcije možemo pronaći iterativnim postupkom ažuriranjem vrijednosti x u smjeru koji je suprotan gradijentu ∇f, sve dok se ne približimo nuli na zadanu preciznost ε:

$$x_{n+1} = x_n - \eta \nabla f(x) \tag{10}$$

η je stopa učenja, za koju, ako je prevelika, postupak divergira, a ako je premala, postupak sporo konvergira.

Ako je funkcija konveksna, pronađeni minimum ujedno je i globalni minimum, u protivnom može biti lokalni.

Slika C.1. Gradijentni spust

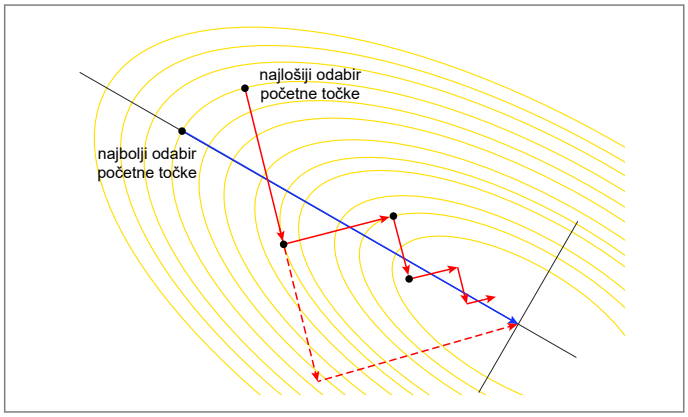

Izvor: Šnajder (2017.)

XGB rabi ansambl stabala odluke, pri čemu se model trenira na sumirajući (engl. *additive*, odnosno podižući, engl. *boosting*) način, pri čemu XGB uključuje pohlepni algoritam (engl. *greedy algorithm*) koji pohlepno dodaje u model funkciju f_t, koja najviše poboljšava model s obzirom na regularizacijsku funkciju (vidi Chen *et al.*, 2016.). Ansambli su česta metoda pri izgradnji algoritma strojnog učenja, u kojoj se kombinacijom osnovnih klasifikatora gradi jedan metaklasifikator, čime se postižu bolja klasifikacijska svojstva i veća brzina učenja. Na sljedećem skraćenom primjeru objašnjava se algoritam treniranja modela s pomoću ansambla stabala, dok je detaljno objašnjenje dostupno u radu Chen *et al.* (2016.).

Primjer (Chen *et al.*, 2016.): tražimo model koji će prepoznati voli li osoba računalne igre. Ulaz su podaci o dobi, spolu i zanimanju osobe. Algoritam provjerava različita stabla i pohlepno traži optimum za svako stablo te naposljetku dodaje najbolja stabla u model, optimirajući funkciju cilja, koja se sastoji od funkcije gubitka l i regularizacijske funkcije Ω:

$$Obj = \sum_{i=1}^{n} l(y_i \hat{y}_t) + \sum_{k=1}^{K} \Omega(f_k) \tag{11}$$

Svakom listu u stablu dodjeljuje se broj bodova, skor. Podižuće (aditivno) učenje u svakoj iteraciji t sadržano je u sumi funkcija koje su zadržane u prethodnoj iteraciji $t-1$:

$$\begin{gathered} y_i^{(0)} = 0 \\ \hat{y}_i^{(1)} = f_1(x_i) = \hat{y}_i^{(0)} + f_1(x_i) \\ \hat{y}_i^{(2)} = f_1(x_i) + f_2(x_i) = \hat{y}_i^{(1)} + f_2(x_i) \\ \dots \\ \hat{y}_i^{(t)} = \sum_{k=1}^{t} f_k(x_i) = \hat{y}_i^{(t-1)} + f_t(x_i) \end{gathered} \tag{12}$$

Slika C.2. Ansambl stabala

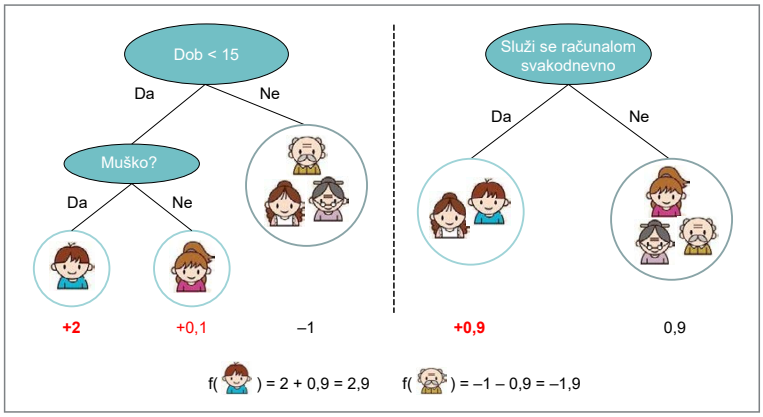

Izvor: Chen et al. (2016.)

U istraživanju je upotrijebljena logistička funkcija gubitka unakrsne entropije l (vidi jednadžbu (7)), a regularizacijska funkcija Ω dana je izrazom (8), uz stopu učenja $\eta = 0,75$ (jednadžba (9) i Slika 4.). Uvrsti li se (12) u funkciju cilja (11), uz uvrštavanje (7) i (8)) te nakon njezine aproksimacije Taylorovim polinomom drugog reda, može se dobiti funkcija cilja sljedećeg oblika (detaljnije vidi Chen *et al.*, 2016.):

$$Obj = -\frac{1}{2}\sum_{j=1}^{T}\frac{G_j^2}{H_j+\lambda} + \gamma T \tag{13}$$

Slika C.3. Izračun skora strukture

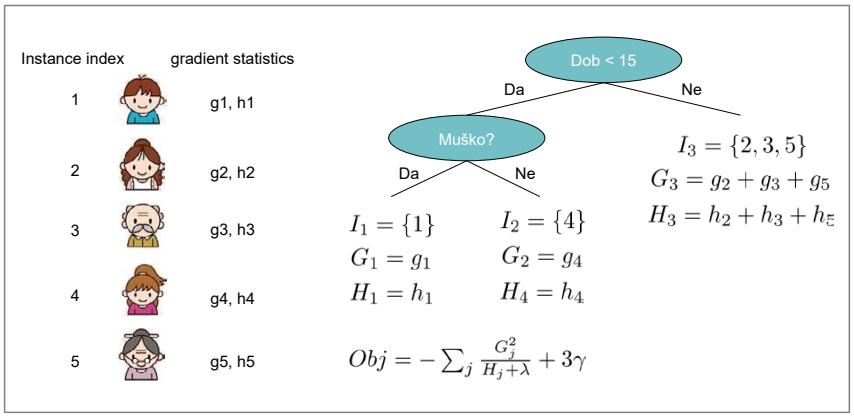

Izvor: Chen et al. (2016.)

pri čemu g_i i h_i označavaju komponente funkcije gradijenata Taylorova polinoma ($g_i = \partial_{\hat{y}^{(t-1)}} l(y_i, \hat{y}^{(t-1)})$, $h_i = \partial^2_{\hat{y}^{(t-1)}} l(y_i, \hat{y}^{(t-1)})$), a G_i i H_i njihove su sume. Stabla su definirana s pomoću vektora skorova listova, a složenost stabala definirana je brojem listova i L_2 normom skorova ((8)). Optimalna podjela listova dobije se linearnim skeniranjem instancija slijeva nadesno, na primjer za pravilo za dob $x_j < a$:

Slika C.4. Optimalna podjela linearnim skeniranjem

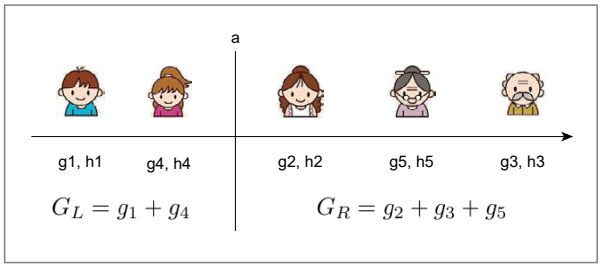

Izvor: Chen et al. (2016.)

Tablica C.1. Točan pohlepni algoritam pronalaženja čvorova

Algoritam 1: Točan pohlepni algoritam pronalaženja čvorišta

ulaz: I, skup instanca trenutačnog čvora

ulaz: d, dimenzija obilježja

$dobit \leftarrow 0$

$G \leftarrow \sum_{i \in I} g_i, H \leftarrow \sum_{i \in I} h_i$

for $k = 1$ **to** m **do**

  $G_L \leftarrow 0, H_L \leftarrow 0$

  for j **in** sorted(I, by x_{jk}) **do**

    $G_L \leftarrow G_L + g_j, H_L \leftarrow H_L + h_j$

    $G_R \leftarrow G - G_L, H_R \leftarrow H - H_L$

    $score \leftarrow \max(score, \frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{G^2}{H + \lambda})$

  end

end

izlaz: grananje s maksimalnim rezultatom

Izvor: Chen et al. (2016.)

pri čemu je informacijska dobit

$$Gain = \frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} - \gamma \qquad (14)$$

Točan pohlepni algoritam pronalaženja čvorova prikazan je u Tablici C.1., a XGB rabi inačicu tog algoritma koja uključuje prazne (engl. *missing*) vrijednosti. Na taj način grade se stabla plićih i dubljih struktura, koja se potom slažu u ansambl stabala, čineći tako mrežu naučenog znanja. Pravilnim odabirom stope učenja i dubine stabala može

se postići kompromis između prenaučenosti i podnaučenosti modela, što se najčešće provjerava unakrsnom provjerom: model učimo na skupu za učenje (trening-podacima), a provjeravamo na skupu za provjeru (testnim podacima). Budući da klasifikator nije treniran na podacima skupa za provjeru, možemo vrlo dobro procijeniti kako će se klasifikator ponašati na neviđenim podacima, a optimum modela jest onaj u kojem su empirijska pogreška i pogreška generalizacije najmanje:

Slika C.5. Komponente algoritma nadziranog učenja

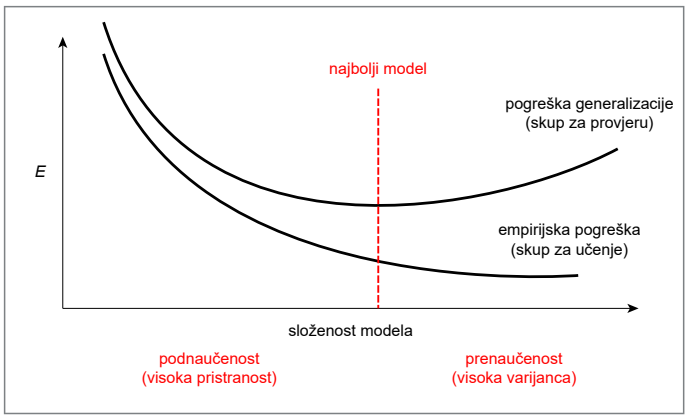

Izvor: Šnajder i Dalbelo Bašić (2014.)

Strojnim učenjem mogu se danas analizirati velike količine podataka i pronalaziti ovisnosti među njima, iako su njihove strukture presložene ili se čine nedovoljno povezanima da bi se iz njih izvukao zaključak. Problem koji se javlja u primjeni dubokoga strojnog učenja (izuzevši prenaučenost) jest i nejasno tumačenje uzročno-posljedičnih i logičkih povezanosti među podacima. Ipak, upravo zbog svoje kompleksnosti, tehnike strojnog učenja postižu općenito bolje rezultate, čemu u prilog govore i natjecanja u strojnom učenju poput Kagglea, gdje natjecatelji nerijetko upotrebljavaju ansamble više različitih modela koji postižu veću preciznost uz cijenu otežanog tumačenja kauzalnosti. Problem je manje izražen kod plosnatijih struktura, koje se ne granaju preduboko, dok pojedinačna stabla ostavljaju dovoljnu razumljivost za segmentiranu interpretaciju uzročno-posljedičnih fenomena. Ovo se istraživanje stoga i ne koristi prevelikom dubinom učenja te istodobno postiže zadovoljavajuće bolje rezultate od usporedno istražene klasične logističke regresije.

Logistička regresija

Logistička je regresija probabilistički diskriminativni model. Unatoč nazivu nije regresija već klasifikacija, čiji izlaz ima vjerojatnosno tumačenje, aposteriorne vjerojatnosti $P(y|x)$:

$$P(x \mid y) = \sigma(\alpha) = \frac{1}{1 + e^{-\alpha}} \tag{15}$$

Logistička funkcija preslikava sve vrijednosti iz domene realnih brojeva na interval <0, 1> (Slika C.6.).

Slika C.6. Logistička ili sigmoidna funkcija

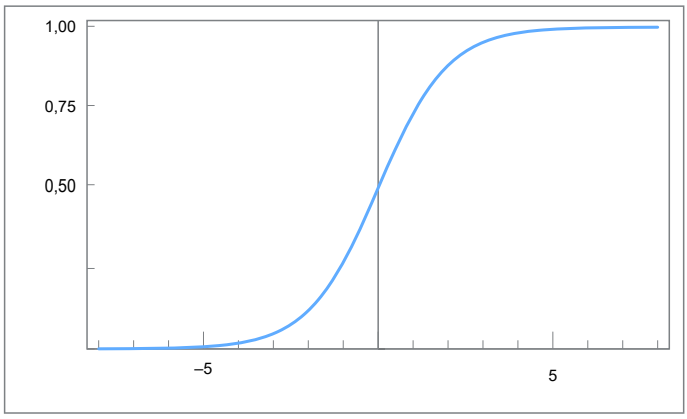

Izvor: Šnajder i Dalbelo Bašić (2014.)

Vrijednost α linearna je kombinacija težina:

$$\alpha = \ln \frac{p(x \mid y = 1)\, P(y = 1)}{p(x \mid y = 0)\, P(y = 0)} = \boldsymbol{w}^T \boldsymbol{x} + w_0 \tag{16}$$

Model za dvije klase (npr. I4.0 ili tradicionalno poduzeće) prikazan je na Slici C.7.

Slika C.7. Model za dvije klase, aposteriorna vjerojatnost modelirana logističkom funkcijom

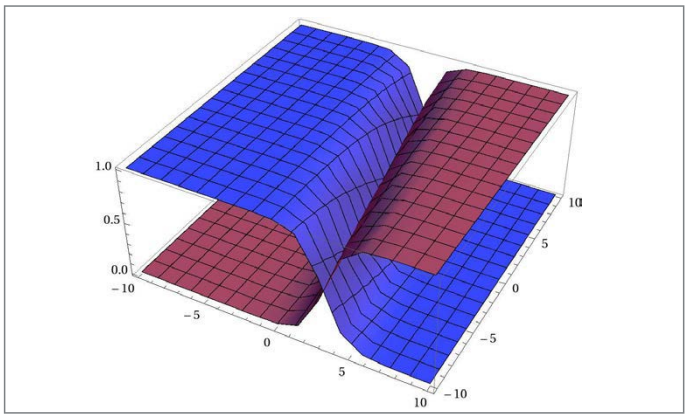

Izvor: Šnajder i Dalbelo Bašić (2014.)

Slika C.8. Signifikantnost varijabla u 20 iteracija logističke regresije

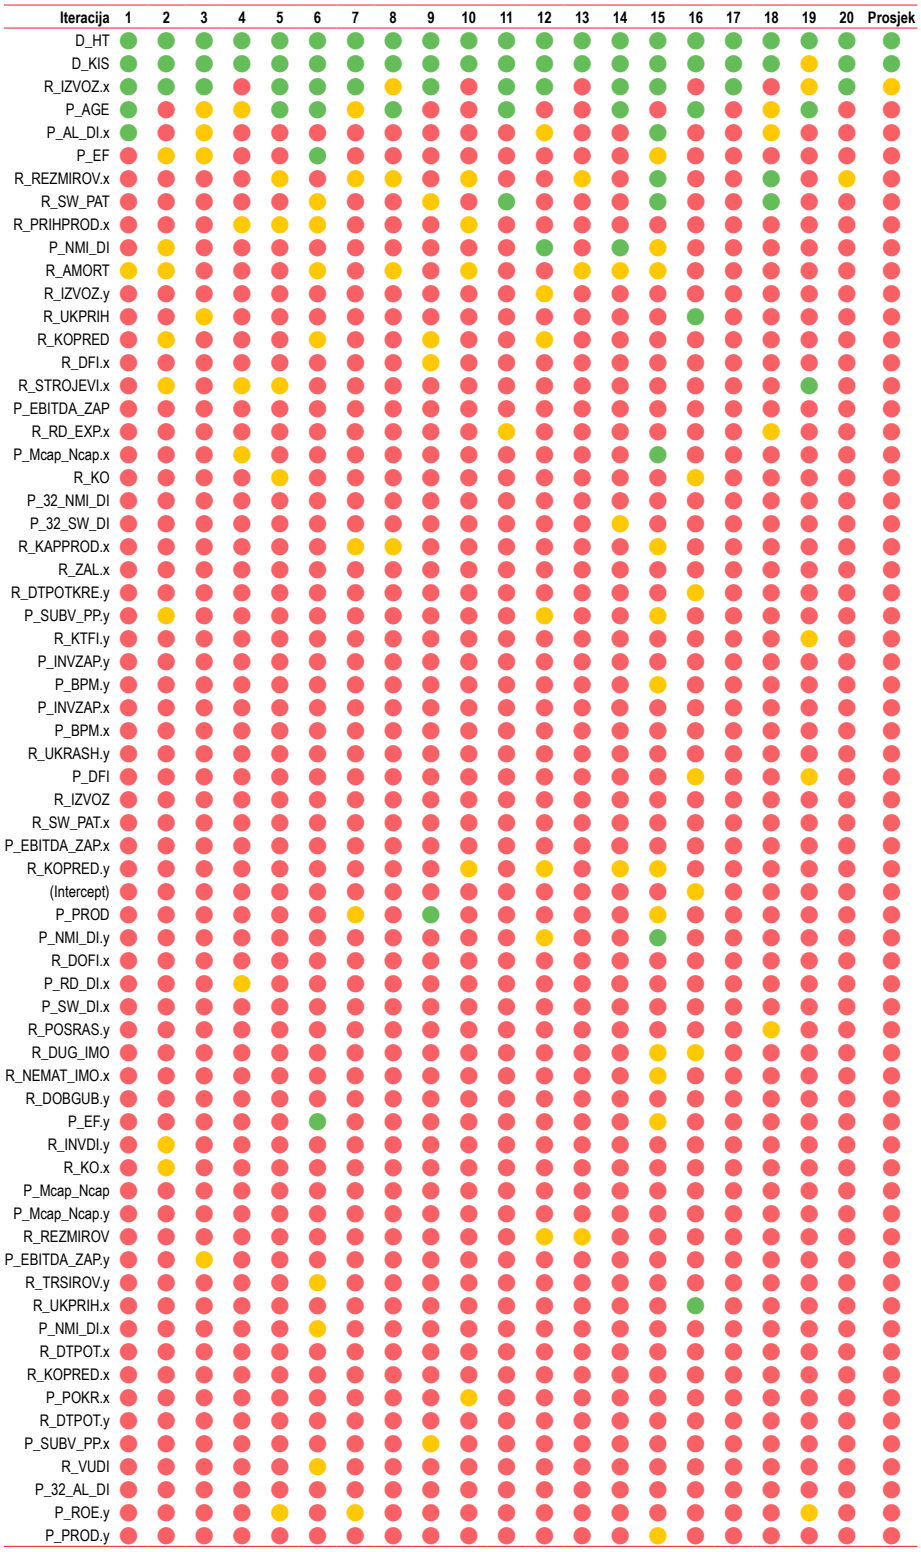

Napomena: ●... >5%, ●... 1–5% ●...<1%

Učenje modela logističke regresije svodi se na određivanje parametara w iz izraza (16), odnosno procjenitelje $\tilde{\boldsymbol{w}}$ za $h(x) = \sigma(\tilde{\boldsymbol{w}}^T \tilde{\boldsymbol{x}})$. Rješavanje optimizacijskog problema logističke regresije također najčešće rabi gradijentni spust i tipično L_2 regularizaciju.

U istraživanju je primijenjena logistička regresija u iterativnom postupku na 20 uzoraka za učenje i isto toliko uzoraka za provjeru. Iako su u prosjeku dobivena diskriminatorna svojstva logističke regresije usporediva s diskriminatornim svojstvima dobivenima XGB metodom, prenaučenost je logističkom regresijom veća, što je vidljivo na Slici 4. i Slici 6. Slika C.8. prikazuje signifikantnost varijabla u iteracijama logističke regresije, poredane od najveće prosječne signifikantnosti prema manjoj. Logistička je regresija češće divergirala tijekom iteracija, u prosjeku više od 70% puta, pa je postupak bilo potrebno više puta ponavljati kako bi se postigla konvergencija na 20 različitih uzoraka.

Slika C.8. pokazuje da su statistički najznačajnije varijable upravo one koje su ušle u model XGB, no logistička ih regresija ne sintetizira u jedan model, kao što to uspijeva ansambl stabala odlučivanja.

Literatura

Acemoglu, D. i Restrepo, P. (2017.): *Robots and jobs: evidence from US labor markets*, NBER working paper series, dostupno na: http://www.nber.org/papers/w23285 [7. veljače 2019.]

Bai, C. *et al.* (2020.): *Industry 4.0 technologies assessment: A sustainability perspective*, International Journal of Production Economics

BCG: *Embracing Industry 4.0 and Rediscovering Growth*, Boston Consulting Group, dostupno na: https://www.bcg.com/capabilities/operations/embracing-industry-4.0-rediscovering-growth.aspx [8. ožujka 2020.]

Blunck, E. i Werthmann, H. (2017.): *Industry 4.0 – an opportunity to realize sustainable manufacturing and its potential for a circular economy*, Dubrovnik International Economic Meeting, (3) 1

Bughin, J., Staun, J., Andersen, J., Schultz-Nielsen, M., Aagaard, P. i Enggaard, T. (2017.): *Digitally-enabled automation and artificial intelligence: Shaping the future of work in Europe's digital front-runners*, McKinsey & Company, listopad, dostupno na: https://www.mckinsey.com/featured-insights/europe/shaping-the-future-of-work-in-europes-nine-digital-front-runner-countries [6. svibnja 2019.]

Cerved, 2017. (2017.): *Cerved SMEs report*, dostupno na: https://know.cerved.com/imprese-mercati/2017-cerved-smes-report/ [5. veljače 2019.]

Chen, T. *et al.* (2016.): *XGBoost: A Scalable Tree Boosting System*, KDD, San Francisco, CA, USA, dostupno na: https://www.kdd.org/kdd2016/papers/files/rfp0697-chenAemb.pdf [14. veljače 2020.]

Eurostat (2016.): *Eurostat indicators on High-tech industry and Knowledge – intensive services*, Annex 3 – High-tech aggregation by NACE Rev.2, Eurostat Reference Metadata in Euro SDMX Metadata Structure (ESMS), dostupno na: https://ec.europa.eu/eurostat/cache/metadata/Annexes/htec_esms_an3.pdf [25. veljače 2019.]

Fina (2019.): *Dokumentacija PD modela i metodologije za izračun kreditnog rejtinga poduzetnika u skladu s Basel III smjernicama ver. 2.1*, dostupno na: https://www.fina.hr/documents/52450/138867/Dokumentacija+PD+modela+i+metodologije+za+izracun.pdf [23. srpnja 2020.]

Frey, C. i Osborne, M. (2013.): *The future of employment: how susceptible are jobs to computerisation?*, University of Oxford

EIB (2018.): *Izvješće o radu za 2017.*, Europska investicijska banka, EIB

McKinsey (2018.): *Croatia – Emerging Digital Challenger Digitization as the new growth engine for Croatia*, prezentacija, McKinsey & Company, studeni, dostupno na: https://digitalchallengers.mckinsey.com/files/Digital-Challengers-Perspective-on-Croatia.pdf [19. siječnja 2020.]

Novak, J. *et al.* (2018.): *The rise of Digital Challengers: How digitalization can become the next growth engine for Central and Eastern Europe*, McKinsey, dostupno na: https://www.mckinsey.com/~/media/McKinsey/Featured%20Insights/Europe/Central%20and%20Eastern%20Europe%20needs%20a%20new%20engine%20for%20growth/The-rise-of-Digital-Challengers.ashx [19. siječnja 2020.]

Petropoulos, A. *et al.* (2018.): *A robust machine learning approach for credit risk analysis of large loan level datasets using deep learning and extreme gradient boosting*, BIS, dostupno na: https://www.bis.org/ifc/publ/ifcb49_49.pdf [22. ožujka 2020.]

PwC (2014.): *Industry 4.0 – Opportunities and Challenges of the Industrial Internet*, dostupno na: https://www.pwc.nl/en/assets/documents/pwc-industrie-4-0.pdf [12. veljače 2019.]

Šnajder, J. (2017.): *Strojno učenje – natuknice za predavanja*, Fakultet elektrotehnike i računarstva

Šnajder, J. i Dalbelo Bašić, B. (2014.): *Strojno učenje – skripta*, Fakultet elektrotehnike i računarstva

Veža, I., Gjeldum, N. i Mladineo, M. (2018.): *Inovativno pametno poduzeće*, Fakultet strojarstva i brodogradnje

Popis slika i tablica

Popis slika

Slika 1. Distribucija trening-uzorka 16

Slika 2. Distribucija testnog uzorka..... 16

Slika 3. Diskriminatorna snaga i stabilnost modela XGB na promjene parametara gama i eta..... 18

Slika 4. Ginijevi koeficijenti trening-uzoraka i testnih uzoraka uz optimalne parametre gama i eta (XGB)..... 20

Slika 5. Ukupna informacijska dobit pojedinih varijabla u 20 iteracija..... 20

Slika 6. Diskriminatorna snaga logističkog modela..... 21

Slika 7. Informacijska dobit varijabla konačnog modela 21

Slika 8. Krivulja kumulativnog profila preciznosti (CAP) konačnog modela na trening-uzorku..... 22

Slika 9. Krivulja kumulativnog profila preciznosti (CAP) konačnog modela na testnom uzorku..... 22

Slika 10. Funkcija gustoće distribucije potencijala I4.0..... 23

Slika 11. Distribucija potencijala I4.0 prema razredima djelatnosti..... 24

Slika 12. Potencijali I4.0 prema veličini poduzeća 25

Slika 13. Distribucije granične stope tehničke supstitucije (MRTS)..... 28

Slika 14. Distribucije prosječnih godišnjih troškova osoblja po zaposlenom..... 29

Slika 15. Distribucije udjela izvoza u poslovnim prihodima 29

Slika 16. Distribucije udjela istraživanja i razvoja u dugotrajnoj imovini..... 30

Slika 17. Distribucija vjerojatnosti zastoja u plaćanju (PD)..... 31

Slika 18. Distribucija proporcija poduzeća po razredima rejtinga[10]..... 32

Slika B.1. Stablo modela XGBoost 41

Slika C.1. Gradijentni spust..... 43

Slika C.2. Ansambl stabala 44

Slika C.3. Izračun skora strukture 44

Slika C.4. Optimalna podjela linearnim skeniranjem 45

Slika C.5. Komponente algoritma nadziranog učenja 46

Slika C.6. Logistička ili sigmoidna funkcija 47

Slika C.7. Model za dvije klase, aposteriorna vjerojatnost modelirana logističkom funkcijom 47

Slika C.8. Signifikantnost varijabla u 20 iteracija logističke regresije 48

Popis tablica

Tablica 1. Broj analiziranih subjekata prema različitim uzorcima 13

Tablica 2. Broj analiziranih subjekata prema različitim djelatnostima 13

Tablica 3. Neprobabilistički uzorak prema veličini poduzeća 13

Tablica 4. Struktura trening-uzorka I4.0 po veličini poduzeća 16

Tablica 5. Struktura testnog uzorka I4.0 po veličini poduzeća 17

Tablica 6. Rangiranje rezultata iteracija prema optimizacijskim kriterijima 19

Tablica 7. Broj i udio poduzeća s potencijalom za I4.0 prema industriji – neprobabilistički uzorak 24

Tablica 8. Potencijali industrije 4.0 26

Tablica 9. Usporedni prikaz uzoraka i potencijala 27

Tablica 10. ANOVA granične stope tehničke supstitucije 28

Tablica 11. ANOVA prosječnog troška zaposlenika 29

Tablica 12. ANOVA udjela izvoza u poslovnim prihodima 30

Tablica 13. ANOVA udjela ulaganja u istraživanje i razvoj u dugotrajnoj imovini 30

Tablica 14. ANOVA vjerojatnosti zastoja u plaćanju 31

Tablica A.1. Popis identificiranih tehnologija I4.0 u hrvatskim poduzećima..... 35

Tablica B.1. Popis nezavisnih varijabla iz financijskih izvješća i zavisna varijabla 38

Tablica B.2. Popis pokazatelja..... 39

Tablica C.1. Točan pohlepni algoritam pronalaženja čvorova 45

IZDAVAČ
Hrvatska narodna banka
Trg hrvatskih velikana 3
10000 Zagreb
T. +385 1 4564 555
www.hnb.hr

GLAVNI UREDNIK
Ljubinko Jankov

UREDNIŠTVO
Vedran Šošić
Gordi Sušić
Davor Kunovac
Maroje Lang
Davor Galinec
Maja Bukovšak
Dražen Odorčić
Boris Cota
Tomislav Ridzak
Evan Kraft
Ante Žigman

IZVRŠNI UREDNIK
Katja Gattin Turkalj

LEKTORICA
Dragica Platužić

DIZAJNER
Vjekoslav Gjergja

GRAFIČKI UREDNIK
Slavko Križnjak

Za stajališta iznesena u ovom radu odgovorni su autori i ta stajališta nisu nužno istovjetna službenim stajalištima Hrvatske narodne banke.

Molimo korisnike ove publikacije da pri korištenju podataka obvezno navedu izvor.

ISSN 1334-0077 (online)

Procjena spremnosti hrvatskih poduzeća na uvođenje tehnologija I4.0

ISSN 1334-0077 (online)