Primljeno/Submitted: 04.05.2026.
Prihvaćeno/Accepted: 25.05.2026.

Pregledni rad
Review paper

PREDIKTIVNA ANALITIKA I ODRŽIVO POSLOVANJE: ULOGA IT ALATA U DONOŠENJU STRATEŠKIH ODLUKA

PREDICTIVE ANALYTICS AND SUSTAINABLE BUSINESS: THE ROLE OF IT TOOLS IN STRATEGIC DECISION-MAKING

Nešad Krnjić*
Admir Sivro**

SAŽETAK

Ovaj rad istražuje ulogu prediktivne analitike u održivom poslovanju, s fokusom na doprinos IT alata u procesu donošenja strateških odluka. Prediktivna analitika, zasnovana na statističkim modelima, mašinskom učenju i obradi velikih količina podataka, omogućava organizacijama identifikaciju trendova, smanjenje rizika i optimizaciju poslovnih procesa. Metodološki pristup rada zasniva se na analizi relevantne naučne literature, komparativnoj analizi tradicionalnih i podacima vođen (*engl. Data-driven*) pristup modela odlučivanja, te studijama slučaja iz sektora finansija, zdravstva, maloprodaje i industrijske proizvodnje. Rezultati istraživanja ukazuju da primjena prediktivne analitike može doprinijeti smanjenju troškova, unapređenju kvaliteta donošenja odluka i povećanju konkurentnosti organizacija. Istovremeno, identifikovani su i određeni izazovi, uključujući pogrešnu interpretaciju podataka, prekomjerno oslanjanje na tehnologiju i potrebu za stručnim kadrom. Diskusija naglašava važnost balansiranja između ljudske prosudbe i analitičkih sistema, uz odgovorno upravljanje podacima i etičku primjenu tehnologije. Zaključuje se da prediktivna analitika predstavlja značajan faktor digitalne transformacije i može doprinijeti dugoročno održivom poslovanju.

Ključne riječi: prediktivna analitika**,** održivo poslovanje**,** IT alati**,** strateško odlučivanje**,** digitalna transformacija

ABSTRACT

This paper explores the role of predictive analytics in sustainable business, with a particular focus on the contribution of IT tools to strategic decision-making processes. Predictive analytics, based on statistical models, machine learning, and big data processing, enables organizations to identify trends, reduce risks, and optimize business operations. The methodological approach is based on the analysis of relevant scientific literature, comparative analysis of traditional and data-driven decision-making models, and case studies from the financial, healthcare, retail, and industrial sectors. The research findings indicate that

* Sveučilište/Univerzitet "VITEZ" Fakultet informacijskih tehnologija, docent, nesad.krnjic@unvi.edu.ba
*** Sveučilište/Univerzitet "VITEZ" Fakultet informacijskih tehnologija, magistar, sivro.admir@unvi.edu.ba

predictive analytics can contribute to cost reduction, improved decision-making quality, and enhanced organizational competitiveness. At the same time, several challenges were identified, including data misinterpretation, excessive reliance on technology, and the need for qualified professionals. The discussion emphasizes the importance of balancing human judgment and analytical systems, along with responsible data governance and ethical use of technology. The paper concludes that predictive analytics represents an important factor of digital transformation and can contribute to long-term sustainable business development.

Keywords: predictive analytics, sustainable business, IT tools, strategic decision-making, digital transformation

UVOD

Savremeno poslovno okruženje karakterišu ubrzane tehnološke promjene, visoka tržišna dinamika i rastuća kompleksnost procesa odlučivanja, zbog čega strateško upravljanje postaje ključni faktor dugoročne održivosti organizacija. U uslovima globalizacije, digitalne transformacije i sve intenzivnije konkurencije, organizacije više ne mogu zasnivati svoje odluke isključivo na intuiciji, iskustvu menadžera ili historijskim podacima posmatranim izolovano. Umjesto toga, neophodno je koristiti sistematične, podatkovno vođene pristupe koji omogućavaju anticipaciju budućih događaja i pravovremeno reagovanje na promjene u poslovnom okruženju. Strateško odlučivanje podrazumijeva izbor dugoročnih pravaca razvoja organizacije, alokaciju resursa i definisanje konkurentske pozicije na tržištu. Prema savremenim teorijama strateškog menadžmenta, kvalitet ovih odluka direktno utiče na održivost poslovanja, profitabilnost i sposobnost adaptacije organizacije (Porter, 1985).

Tradicionalni modeli odlučivanja, iako i dalje prisutni, suočavaju se sa ograničenjima u kontekstu obrade velikih količina podataka i prepoznavanja kompleksnih obrazaca koji utiču na poslovne performanse. U tom kontekstu, razvoj informacionih tehnologija i analitičkih alata doveo je do pojave prediktivne analitike kao jednog od najznačajnijih instrumenata savremenog menadžmenta. Prediktivna analitika predstavlja skup metoda i tehnika koje koriste statističke modele, algoritme mašinskog učenja i obradu velikih skupova podataka (*engl. Big Data*) s ciljem predviđanja budućih događaja i trendova (Jamarani et al., 2024). Za razliku od deskriptivne analitike, koja odgovara na pitanje „šta se dogodilo“, i dijagnostičke analitike, koja objašnjava „zašto se nešto dogodilo“, prediktivna analitika omogućava odgovor na ključno strateško pitanje: „šta će se dogoditi i kako se organizacija može pravovremeno pripremiti?“ Chen, Chiang i Storey (2012) ističu da razvoj poslovne inteligencije i analitike značajno transformiše način na koji organizacije koriste podatke za donošenje strateških odluka i ostvarivanje konkurentske prednosti. Iz perspektive informacionih sistema, prediktivna analitika implementira se kroz različite IT alate i platforme, kao što su sistemi za poslovnu inteligenciju (*engl. Business Intelligence – BI*), sistemi za centralizovano skladištenje i analizu poslovnih podataka (*engl. Data Warehouse*), računarske usluge u oblaku kao (*engl. Cloud*) platforme i okruženja za razvoj modela mašinskog učenja. Ovi alati omogućavaju integraciju podataka iz različitih izvora, njihovu transformaciju i analizu, te generisanje prediktivnih modela koji podržavaju donošenje odluka na svim nivoima upravljanja. Davenport i Harris (2007) navode da organizacije koje primjenjuju analitički vođene modele ostvaruju značajne prednosti u efikasnosti poslovanja,

razumijevanju tržišta i brzini reakcije na promjene. Pored toga, prediktivna analitika ima značajnu ulogu u konceptu održivog poslovanja. Održivo poslovanje podrazumijeva balansiranje ekonomskih, ekoloških i društvenih ciljeva uz efikasno korištenje resursa i dugoročnu stabilnost organizacije. Prediktivni modeli omogućavaju optimizaciju potrošnje resursa, smanjenje otpada, efikasnije planiranje proizvodnje i bolje upravljanje lancima snabdijevanja. Na taj način organizacije ne samo da unapređuju profitabilnost i operativnu efikasnost, već doprinose i ostvarivanju ciljeva održivog razvoja kroz racionalnije upravljanje resursima i smanjenje negativnih uticaja na okoliš. Cilj ovog rada jeste analizirati ulogu prediktivne analitike u procesu donošenja strateških odluka i ispitati njen doprinos održivom poslovanju kroz primjenu savremenih IT alata i analitičkih modela. Rad se zasniva na analizi relevantne naučne literature, industrijskih izvještaja i studija slučaja iz različitih sektora poslovanja. Poseban fokus stavljen je na ekonomske i poslovne efekte primjene prediktivne analitike, kao i na izazove povezane sa implementacijom data-driven pristupa u organizacijama. Naučni doprinos rada ogleda se u integraciji perspektiva informacionih tehnologija, strateškog menadžmenta i održivog poslovanja kroz interdisciplinarnu analizu primjene prediktivne analitike u savremenim organizacijama.

1. TEORIJSKI OKVIR

Digitalna transformacija savremenog poslovanja dovela je do eksponencijalnog rasta količine podataka, zbog čega je sposobnost njihove analize postala jedan od ključnih faktora konkurentnosti organizacija. U takvom okruženju, prediktivna analitika predstavlja poveznicu između sirovih podataka i strateških poslovnih odluka, omogućavajući organizacijama da identifikuju obrasce, procijene rizike i pravovremeno reaguju na promjene u poslovnom okruženju.

1.1. Definicija prediktivne analitike i osnovni principi

Prediktivna analitika može se definisati kao skup metoda i tehnika koje koriste historijske podatke, statističke modele i algoritme mašinskog učenja (*engl. Machine Learning – ML*) s ciljem identifikacije obrazaca i predviđanja budućih ishoda. Za razliku od tradicionalnih analitičkih pristupa, koji su primarno deskriptivni, prediktivna analitika ima proaktivnu dimenziju i omogućava organizacijama anticipaciju promjena i optimizaciju poslovnih strategija (Jamarani et al., 2024). Osnovni principi prediktivne analitike obuhvataju tri ključna segmenta:

1.1.1. Statistički modeli

Statistički modeli predstavljaju temelj prediktivne analitike. Među najčešće korištenim metodama izdvajaju se linearna i logistička regresija, modeli vremenskih serija (*engl. ARIMA – AutoRegressive Integrated Moving Average*) odnosno modeli za analizu trendova i predviđanje budućih vrijednosti na osnovu historijskih podataka i Bayesovi modeli. Na primjer, logistička regresija često se koristi za klasifikacione probleme, kao što je procjena

vjerovatnoće da će korisnik napustiti određenu uslugu ili da će doći do kašnjenja u otplati kredita.

1.1.2. Mašinsko učenje

Mašinsko učenje predstavlja napredniji pristup u kojem algoritmi „uče“ iz podataka bez eksplicitnog programiranja pravila. Najznačajnije kategorije uključuju nadgledano učenje, poput stabala odlučivanja (*engl. Decision Trees*), modeli slučajnih šuma (*engl. Random Forest*) i modeli za klasifikaciju i analizu podataka (*engl. Support Vector Machine - SVM*), nenadgledano učenje koje se koristi za klasterovanje (grupisanje sličnih podataka) i segmentaciju tržišta, te duboko učenje zasnovano na neuralnim mrežama, odnosno modelima inspirisanim načinom rada ljudskog mozga, za prepoznavanje kompleksnih obrazaca u velikim skupovima podataka.

1.1.3. Big Data

Razvoj prediktivne analitike direktno je povezan sa pojavom paradigme velikih podataka (*engl. Big Data*), koju karakterišu velike količine podataka, velika brzina njihove obrade i raznovrsnost izvora podataka. Tehnologije poput Hadoop i Spark platformi omogućavaju distribuiranu obradu podataka, odnosno paralelnu obradu velikih skupova podataka na više računarskih čvorova, dok cloud platforme, kao što su Amazon Web Services (AWS) i Microsoft Azure, pružaju skalabilnu infrastrukturu za implementaciju i izvršavanje analitičkih modela (Chen, Chiang & Storey, 2012). Gandomi i Haider (2015) naglašavaju da vrijednost Big Data koncepta ne proizlazi isključivo iz količine podataka, već iz sposobnosti organizacija da podatke transformišu u korisne poslovne uvide.

1.2. Teorije strateškog menadžmenta i održivog poslovanja

Savremeni strateški menadžment sve se više oslanja na pristupe koji naglašavaju značaj organizacijskih resursa, prilagodljivosti i donošenja odluka zasnovanih na podacima. Teorija zasnovana na organizacijskim resursima (*engl. Resource-Based View - RBV*), polazi od pretpostavke da interni resursi i sposobnosti organizacije predstavljaju ključni izvor konkurentske prednosti, dok teorija dinamičkih sposobnosti (*engl. Dynamic Capabilities Theory*) naglašava sposobnost organizacije da kontinuirano prilagođava resurse i poslovne procese promjenama u poslovnom okruženju. Istovremeno, koncept donošenja odluka zasnovanih na podacima (engl. *Data-Driven Decision Making – DDDM*) podrazumijeva korištenje analitičkih metoda i poslovnih podataka u procesu strateškog odlučivanja. Primjena prediktivne analitike doprinosi realizaciji navedenih koncepata kroz optimizaciju potrošnje energije, smanjenje operativnih troškova i emisija štetnih gasova, preciznije predviđanje potražnje i smanjenje otpada, kao i kvalitetniju analizu društvenih podataka radi boljeg razumijevanja potreba korisnika i zajednice. Na taj način prediktivna analitika postaje važan alat za implementaciju održivih poslovnih strategija i unapređenje dugoročne konkurentnosti organizacija.

1.3. Dosadašnja istraživanja i primjena u praksi

Brojna empirijska istraživanja potvrđuju značajan uticaj prediktivne analitike na poslovne performanse i strateško odlučivanje. Prema istraživanju Adesina et al. (2024), organizacije koje koriste data-driven pristupe ostvaruju veću operativnu efikasnost, preciznije planiranje i brže donošenje odluka. Sistematski pregled literature koji su proveli Jamarani et al. (2024) pokazuje da se prediktivna analitika najčešće primjenjuje u oblastima finansija, zdravstva, marketinga i industrijske proizvodnje. U finansijskom sektoru prediktivni modeli koriste se za procjenu kreditnog rizika i otkrivanje prevara, dok se u zdravstvu primjenjuju za dijagnostiku i prevenciju bolesti. U marketingu se koriste za segmentaciju korisnika i personalizaciju ponude, a u proizvodnji za prediktivno održavanje i optimizaciju proizvodnih procesa. Na osnovu analiziranih teorijskih koncepata i empirijskih nalaza može se zaključiti da prediktivna analitika predstavlja most između podataka i strateških odluka, jer omogućava transformaciju sirovih informacija u konkretne i primjenjive poslovne uvide. Integracijom statističkih metoda, algoritama mašinskog učenja i Big Data tehnologija organizacije unapređuju sposobnost identifikacije obrazaca, procjene rizika i donošenja informisanih strateških odluka. Iako brojna istraživanja ukazuju na pozitivne efekte prediktivne analitike, pojedini autori upozoravaju na izazove povezane s kvalitetom podataka, transparentnošću algoritama i rizikom prevelikog oslanjanja na automatizovane modele odlučivanja (Dwivedi et al., 2023). Navedeni izazovi posebno dolaze do izražaja u organizacijama koje nemaju razvijenu analitičku infrastrukturu i stručne kadrove za interpretaciju rezultata.

2. METODOLOGIJA

Metodološki pristup ovog rada zasniva se na kombinaciji kvalitativnih i komparativnih istraživačkih metoda s ciljem sveobuhvatnog razumijevanja uloge prediktivne analitike u savremenom poslovanju. Uzimajući u obzir interdisciplinarnu prirodu teme, metodologija integriše analizu literature, studije slučaja i komparativnu analizu modela odlučivanja, čime se omogućava povezivanje teorijskih koncepata sa rezultatima prethodnih istraživanja i praktičnim primjerima primjene prediktivne analitike u različitim sektorima poslovanja.

2.1. Izvori podataka i istraživački pristup

Istraživanje se temelji na sekundarnoj analizi podataka preuzetih iz naučnih članaka, industrijskih izvještaja i javno dostupnih studija slučaja iz oblasti prediktivne analitike i održivog poslovanja. Pored industrijskih izvještaja, korišteni su i recenzirani naučni članci iz oblasti sistema poslovne inteligencije (*engl. Business Intelligence – BI*), pristupa odlučivanju zasnovanom na podacima (*engl. Data-Driven Decision Making – DDDM*) i primjene mašinskog učenja (*engl. Machine Learning – ML*) u poslovnom odlučivanju (Chen et al., 2012; Gandomi & Haider, 2015; Dwivedi et al., 2023). Podaci korišteni u tabelama i grafikonima zasnovani su na analizama i istraživanjima objavljenim od strane IBM-a (2023),

Gartnera (2024), McKinsey Global Institute (2023), kao i specijalizovanih industrijskih studija slučaja iz oblasti prediktivnog održavanja sistema i poslovne inteligencije. Grafički prikazi i komparativne analize predstavljaju sistematizaciju i vizualizaciju sekundarnih podataka s ciljem jasnijeg prikaza efekata primjene prediktivne analitike na poslovne performanse. Studije slučaja uključuju primjere iz sektora finansija, zdravstva, maloprodaje i industrijske proizvodnje, gdje je primjena prediktivne analitike rezultirala smanjenjem troškova, optimizacijom resursa i unapređenjem procesa donošenja odluka.

2.2. Analiza literature i izvještaja

Prvi metodološki korak obuhvata sistematsku analizu relevantne naučne i stručne literature iz oblasti prediktivne analitike, strateškog menadžmenta i održivog poslovanja. Fokus je primarno stavljen na radove objavljene u periodu od 2020. do 2025. godine, uz uključivanje klasičnih i teorijski značajnih izvora iz ranijeg perioda, kako bi se osigurala aktuelnost istraživanja, pri čemu su uključeni akademski članci, industrijski izvještaji i studije tehnoloških kompanija. Analiza literature imala je tri osnovna cilja: identifikaciju dominantnih modela i tehnika prediktivne analitike, razumijevanje uloge IT alata u poslovnim procesima te evaluaciju uticaja analitičkih pristupa na donošenje strateških odluka. U metodološkom smislu korišten je pristup sličan sistematskom pregledu literature, gdje su izvori klasifikovani prema sektoru primjene (finansije, zdravstvo, maloprodaja i industrija), vrsti analitičkog modela i pokazateljima performansi, kao što su tačnost modela, povrat investicije (Return on Investment – ROI) i smanjenje operativnih troškova. Ovakav pristup omogućava standardizaciju nalaza i njihovu međusobnu komparaciju.

2.3. Studije slučaja (case study pristup)

Drugi ključni element metodologije predstavlja analiza studija slučaja iz različitih industrijskih sektora. Case study metod omogućava detaljnije razumijevanje konkretnih implementacija prediktivne analitike i njihovog uticaja na poslovne rezultate. Odabrane studije slučaja zasnivaju se na sljedećim kriterijima:

- Primjena prediktivnih modela u realnim poslovnim okruženjima.
- Dostupnost mjerljivih rezultata.
- Reprezentativnost za određeni sektor poslovanja.

2.3.1. Bankarstvo i finansije

U finansijskom sektoru institucije poput JPMorgan Chase koriste prediktivne modele za procjenu kreditnog rizika i analizu vjerovatnoće neplaćanja kredita (Davenport & Harris, 2007). Ovi modeli analiziraju historijske podatke korisnika, uključujući kreditnu istoriju, prihode i obrasce ponašanja klijenata. Primijenjene metode uključuju logističku regresiju (*engl. Logistic Regression*), algoritme gradijentnog pojačanja (*engl. Gradient Boosting Algorithms*) za unapređenje tačnosti predikcije i neuronske mreže (*engl. Artificial Neural Networks – ANN*), odnosno modele inspirisane načinom rada ljudskog mozga. Rezultati implementacije ukazuju na smanjenje loših plasmana i unapređenje upravljanja rizicima.

2.3.2. Zdravstvo

U zdravstvenom sektoru organizacije poput IBM Watson Health koriste prediktivnu analitiku za dijagnostiku i prevenciju bolesti (Raghupathi & Raghupathi, 2014). Analizom medicinskih zapisa, genetskih podataka i životnih navika pacijenata moguće je rano identifikovati hronična oboljenja i procijeniti rizik razvoja bolesti. Primjena uključuje klasifikacione modele za dijagnostiku i modele vremenskih serija za praćenje progresije bolesti. Rezultati ukazuju na smanjenje troškova liječenja i efikasnije korištenje medicinskih resursa.

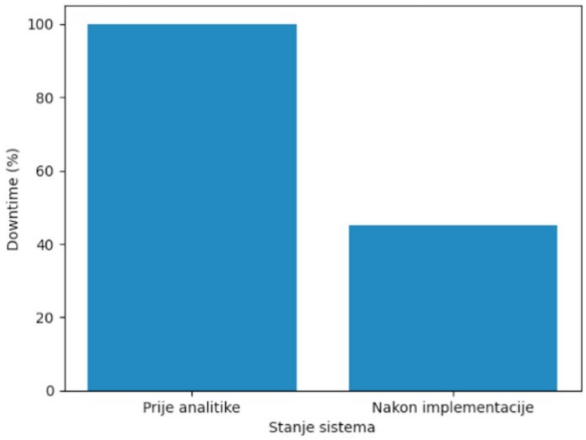
2.3.3. Maloprodaja

Kompanije poput Amazon i Walmart koriste prediktivne algoritme za analizu ponašanja kupaca i optimizaciju poslovanja (Chen et al., 2012). Najčešće korištene tehnike uključuju sisteme preporuke (*engl. Recommendation Systems*), analizu vremenskih serija (*engl. Time Series Analysis*) za predviđanje potražnje i klasterovanje korisnika (*engl. Clustering*). Rezultati implementacije ukazuju na povećanje prodaje kroz personalizaciju ponude, optimizaciju zaliha i smanjenje logističkih troškova.

2.3.4. Industrija i proizvodnja

U industrijskom sektoru kompanije poput Siemens implementiraju prediktivno održavanje (*engl. Predictive Maintenance*), korištenjem senzora Interneta stvari (*engl. Internet of Things – IoT*) i analitičkih modela (Lee et al., 2014).

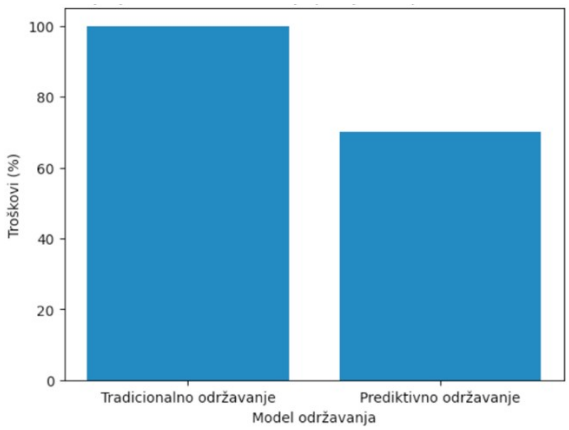
Grafikon 1: Smanjenje neplaniranih zastoja primjenom prediktivne analitike



Izvor: obrada autora na osnovu podataka iz IBM (2023), Gartner (2024) i McKinsey Global Institute (2023).

Proces prediktivnog održavanja obuhvata prikupljanje senzorskih podataka, detekciju anomalija i predviđanje potencijalnih kvarova primjenom analitičkih modela. Rezultati implementacije ukazuju na smanjenje neplaniranih zastoja, povećanje dostupnosti opreme i optimizaciju troškova održavanja.

Grafikon 2: Smanjenje troškova održavanja primjenom prediktivne analitike



Izvor: obrada autora na osnovu podataka iz IBM (2023), Gartner (2024) i McKinsey Global Institute (2023).

2.3.5. Komparativna analiza modela odlučivanja

Treći metodološki segment istraživanja odnosi se na komparativnu analizu između tradicionalnih pristupa donošenju odluka i savremenih data-driven modela odlučivanja zasnovanih na analizi podataka. Cilj ove analize je identifikovati ključne razlike u efikasnosti, brzini donošenja odluka, preciznosti i upravljanju rizicima. Tradicionalni modeli odlučivanja oslanjaju se prvenstveno na iskustvo menadžmenta, heuristički pristupi, odnosno pristupi zasnovani na iskustvenim pravilima i procjenama i ograničene količine historijskih podataka, dok data-driven pristupi koriste napredne metode prediktivne analitike, uključujući statističke modele i algoritme mašinskog učenja (Shmueli et al., 2020). Ovakav pristup omogućava organizacijama unapređenje procesa donošenja odluka kroz objektivnu analizu velikih skupova podataka. U nastavku je prikazana komparativna analiza ova dva pristupa.

Tabela 1: Poređenje tradicionalnog i data-driven pristupa donošenju odluka

Karakteristika	Tradicionalno odlučivanje	Data-driven odlučivanje
Osnova	Iskustvo i intuicija	Podaci i modeli
Brzina	Sporija	Brža
Preciznost	Subjektivna	Kvantitativna
Skalabilnost	Ograničena	Visoka
Rizik	Veći	Smanjen

Izvor: obrada autora na osnovu (Shmueli et al., 2020; Davenport & Harris, 2007; Adesina et al., 2024)

Rezultati komparativne analize ukazuju da data-driven pristupi omogućavaju značajno veću preciznost i brzinu donošenja odluka u odnosu na tradicionalne metode. Također, analitički modeli doprinose proaktivnom upravljanju rizicima, dok tradicionalni pristupi uglavnom djeluju reaktivno. Slične zaključke potvrđuju i Davenport i Harris (2007), koji ističu da organizacije zasnovane na analitičkom odlučivanju ostvaruju veću agilnost i konkurentsku prednost u odnosu na tradicionalne modele upravljanja. Analitički vođeno odlučivanje koristi metrike za evaluaciju modela, kao što su ukupna tačnost modela (*engl. Accuracy*), preciznost klasifikacije (*engl. Precision*), osjetljivost modela (*engl. Recall*) i

metrika koja mjeri sposobnost modela da razlikuje pozitivne i negativne slučajeve (*engl. Receiver Operating Characteristic – Area Under Curve (ROC-AUC)*).

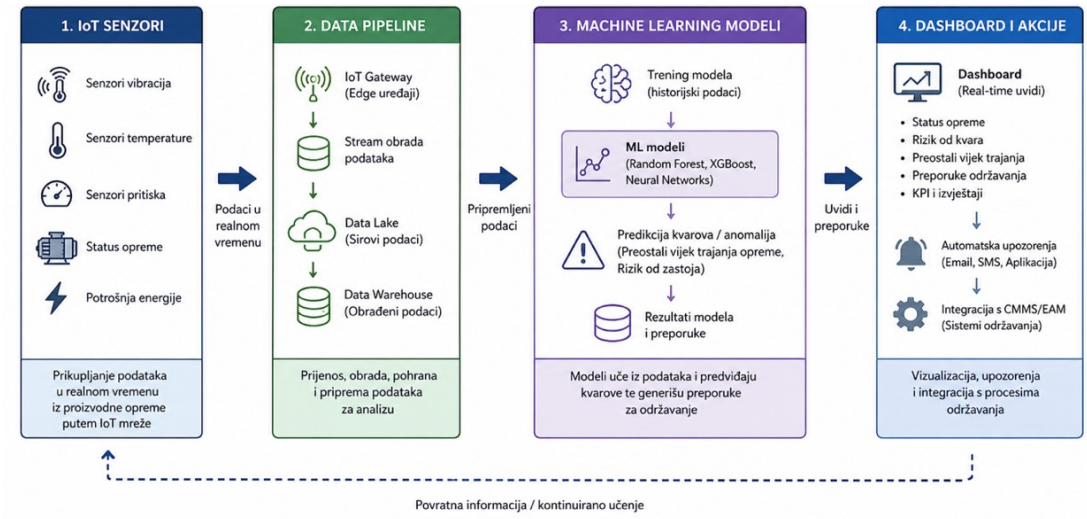
2.4. Validacija i ograničenja metodologije

Kako bi se osigurala validnost rezultata, korištena je triangulacija metoda koja obuhvata teorijsku analizu, empirijske podatke iz studija slučaja i komparativni pristup. Međutim, određena ograničenja istraživanja uključuju zavisnost od dostupnosti sekundarnih podataka, različite metodološke pristupe u analiziranim studijama, kao i potencijalnu pristrasnost prisutnu u pojedinim industrijskim izvještajima. Navedena ograničenja uzeta su u obzir prilikom interpretacije rezultata istraživanja. Primijenjeni metodološki pristup ukazuje da prediktivna analitika može značajno povećati operativnu efikasnost i unaprijediti kvalitet strateških odluka. Kombinacija teorijske analize, studija slučaja i komparativnog pristupa omogućava pouzdan okvir za razumijevanje stvarnog uticaja analitičkih alata u savremenim organizacijama. Accenture (2023) navodi da odgovorna primjena sistema zasnovanih na vještačkoj inteligenciji može doprinijeti održivosti i optimizaciji resursa.

2.5. Arhitektura sistema i tok podataka

U cilju boljeg razumijevanja procesa prediktivne analitike, prikazana je arhitektura sistema koja obuhvata ključne komponente: prikupljanje podataka, obradu, modeliranje i vizualizaciju rezultata. Kao što je prikazano na Grafikonu 3, proces započinje prikupljanjem podataka putem senzora Interneta stvari (Internet of Things – IoT), nakon čega se podaci prenose kroz infrastrukturu za prenos i obradu podataka (data pipeline) za prenos, transformaciju i skladištenje podataka.

Grafikon 3: Arhitektura sistema prediktivne analitike



Izvor: obrada autora na osnovu industrijskih implementacija (IBM, 2023; Gartner, 2024)

U narednoj fazi primjenjuju se algoritmi mašinskog učenja za generisanje predviđanja, dok se rezultati prikazuju kroz kontrolne table (*engl. Dashboard Systems*) za vizualizaciju podataka koji omogućavaju donošenje informisanih odluka. Ovakva arhitektura

predstavlja standardni model implementacije prediktivne analitike u savremenim informacionim sistemima i industrijskim okruženjima.

3. REZULTATI

Na osnovu prethodno definisanog metodološkog pristupa - koji uključuje analizu literature, studije slučaja i komparativnu analizu - rezultati istraživanja ukazuju na značajan uticaj prediktivne analitike na savremeno poslovanje, posebno u segmentima optimizacije resursa, upravljanja rizicima i unapređenja procesa donošenja odluka. Identifikovane koristi mogu se sistematizirati u dvije osnovne kategorije: ekonomske i poslovne, dok se paralelno uočavaju i određeni izazovi koji utiču na uspješnost implementacije analitičkih sistema. U cilju evaluacije efikasnosti prediktivnih modela, analizirane su performanse različitih algoritama mašinskog učenja. Rezultati pokazuju da modeli poput Random Forest algoritma ostvaruju visoku preciznost i stabilnost u predikciji kvarova u industrijskim sistemima (Factored.ai, 2024). Kao što je prikazano u Tabeli 2, Random Forest model ostvaruje visoku precision vrijednost (0.90), ali nešto niži recall (0.60), što ukazuje na kompromis između sposobnosti modela da identifikuje stvarne pozitivne slučajeve i smanjenja broja lažno pozitivnih rezultata. F1-score metrika, koja predstavlja balans između precision i recall vrijednosti, potvrđuje uravnoteženu performansu modela.

Tabela 2: Performanse modela prediktivne analitike

Model	Preciznost (Precision)	Recall (Senzitivnost)	F1-score	AUC-ROC	Specifičnost (Specificity)
Random Forest	**0.9**	**0.6**	**0.73**	**0.94**	**0.93**
XGBoost	0.88	0.65	0.75	0.95	0.91
Artificial Neural Network	0.85	0.58	0.68	0.9	0.89
SVM	0.82	0.5	0.62	0.88	0.86
Logistic Regression	0.78	0.45	0.56	0.83	0.81

Izvor: Factored.ai Case Study – Predictive Maintenance (2024); obrada autora

Radi detaljnijeg razumijevanja performansi Random Forest modela, u nastavku je prikazana matrica konfuzije (*engl. Confusion Matrix*), koja omogućava analizu tačno i netačno klasifikovanih slučajeva.

Tabela 3: Matrica konfuzije – Random Forest model

Predviđanje	Pozitivan slučaj (kvar)	Negativan slučaj (nema kvara)
Pozitivan (kvar)	**TP = 60**	FP = 7
Negativan (nema kvara)	FN = 40	**TN = 93**

Izvor: Factored.ai Case Study – Predictive Maintenance (2024); obrada autora

Rezultati pokazuju da Random Forest model ostvaruje visoku preciznost i AUC-ROC vrijednost u poređenju sa ostalim analiziranim modelima, što ga čini pogodnim za primjenu u sistemima prediktivnog održavanja i industrijskoj analitici. Visoka specifičnost modela (*engl.*

Specificity), odnosno sposobnost modela da pravilno identifikuje negativne slučajeve, vrijednost (0.93) ukazuje na sposobnost modela da pouzdano identifikuje situacije u kojima ne postoji kvar, dok relativno niža osjetljivost modela, sposobnost da prepozna pozitivne slučajeve (*engl. Recall*) pokazuje da određeni broj stvarnih kvarova ostaje neprepoznat. Ovakav kompromis između različitih metrika performansi predstavlja čest izazov u razvoju modela mašinskog učenja za poslovne i industrijske primjene. Na osnovu dobijenih rezultata može se zaključiti da primjena naprednih algoritama mašinskog učenja značajno unapređuje mogućnost predviđanja poslovnih događaja i optimizacije operativnih procesa, čime prediktivna analitika postaje važan element savremenog data-driven poslovanja.

3.1. Ekonomske koristi prediktivne analitike

3.1.1. Smanjenje troškova

Jedan od najznačajnijih efekata primjene prediktivne analitike jeste smanjenje operativnih troškova kroz optimizaciju poslovnih procesa i efikasnije korištenje resursa. Analitički modeli omogućavaju organizacijama identifikaciju neefikasnosti, pravovremeno otkrivanje potencijalnih problema i donošenje preciznijih poslovnih odluka zasnovanih na podacima. Primjena prediktivne analitike prisutna je u različitim sektorima poslovanja. U proizvodnim sistemima koristi se za prediktivno održavanje opreme i smanjenje neplaniranih kvarova, dok u logistici doprinosi optimizaciji transportnih ruta i smanjenju troškova goriva. U energetskom sektoru modeli za predviđanje potrošnje omogućavaju racionalnije upravljanje energetskim resursima i smanjenje nepotrebne potrošnje energije. Prema istraživanju Adesina et al. (2024), implementacija prediktivnih modela u pojedinim sektorima može doprinijeti smanjenju operativnih troškova za približno 20–30%.

Tabela 4: Uticaj prediktivne analitike na poslovne performanse

Pokazatelj	Poboljšanje (%)
Smanjenje troškova održavanja	**10–40%**
Smanjenje neplaniranih zastoja	**do 50%**
Povećanje dostupnosti opreme	**10–20%**
Povećanje produktivnosti	**20–50%**
Smanjenje zaliha rezervnih dijelova	**10–40%**

Izvor: obrada autora na osnovu podataka GITNUX Report (2026).

Prikazani podaci potvrđuju da prediktivna analitika može imati direktan uticaj na povećanje operativne efikasnosti i smanjenje troškova održavanja, posebno u industrijskim i logističkim sistemima.

3.1.2. Optimizacija resursa

Prediktivna analitika omogućava efikasnije upravljanje ograničenim resursima - finansijskim, materijalnim i ljudskim. Kroz analizu historijskih i podataka u realnom vremenu, organizacije mogu preciznije planirati potrebe i izbjeći prekomjernu ili nedovoljnu alokaciju resursa. Najčešće primjene uključuju:

- Optimizaciju zaliha u maloprodaji primjenom just-in-time (*engl. JIT – Just-in-Time*) pristupa upravljanju zalihama.
- Planiranje radne snage na osnovu predviđene potražnje.
- Upravljanje energetskim resursima u industrijskim sistemima.

U informacionim sistemima ovakav pristup implementira se integracijom sistema za planiranje resursa preduzeća (*engl. Enterprise Resource Planning – ERP*) sa analitičkim modulima, pri čemu se prediktivni modeli direktno povezuju sa operativnim procesima organizacije. Na taj način omogućava se automatizovano planiranje resursa i unapređenje poslovne efikasnosti.

3.1.3. Povećanje konkurentnosti

Organizacije koje koriste prediktivnu analitiku ostvaruju konkurentsku prednost kroz brže reakcije na tržišne promjene, bolje razumijevanje potreba korisnika i razvoj inovacija zasnovanih na podacima. Primjena analitičkih modela omogućava organizacijama donošenje preciznijih strateških odluka i prilagođavanje poslovnih procesa dinamičnim tržišnim uslovima. Kompanije poput Amazon koriste napredne algoritme za personalizaciju korisničkog iskustva, čime direktno utiču na povećanje prihoda i lojalnosti kupaca (Chen et al., 2012). Slično tome, Netflix koristi prediktivne modele za preporuku sadržaja i analizu korisničkih preferencija, čime povećava angažman korisnika i smanjuje stopu odustajanja od usluge (Gomez-Uribe & Hunt, 2015). Rezultati navedenih primjera potvrđuju da prediktivna analitika predstavlja važan strateški resurs koji organizacijama omogućava diferencijaciju na tržištu i dugoročno jačanje konkurentske pozicije.

3.2. Poslovne koristi

3.2.1. Bolja procjena rizika

Prediktivna analitika omogućava kvantifikaciju rizika primjenom probabilističkih modela. Umjesto oslanjanja isključivo na subjektivne procjene, menadžeri raspolažu numeričkim indikatorima koji olakšavaju donošenje odluka. Primjer iz bankarskog sektora uključuje procjenu vjerovatnoće neizvršenja kreditnih obaveza i segmentaciju klijenata prema stepenu rizičnosti. Ovakav pristup omogućava preciznije finansijsko planiranje, efikasnije upravljanje rizicima i smanjenje potencijalnih gubitaka.

3.2.2. Unapređenje planiranja

Planiranje, kao jedna od ključnih funkcija menadžmenta, značajno se unapređuje primjenom prediktivne analitike. Organizacije mogu preciznije predviđati potražnju, optimizovati proizvodne cikluse i planirati investicione aktivnosti. Na primjer, kompanija Amazon koristi analizu korisničkih podataka i modele mašinskog učenja za personalizaciju preporuka proizvoda, dok Walmart primjenjuje modele vremenskih serija za predviđanje sezonske potražnje i optimizaciju upravljanja zalihama. Ovakvi pristupi omogućavaju

smanjenje viška zaliha, efikasnije upravljanje lancima snabdijevanja i povećanje operativne efikasnosti.

3.2.3. Brže donošenje odluka

Automatizacija analitičkih procesa omogućava donošenje odluka u realnom vremenu. U sistemima visokog intenziteta podataka, poput finansijskih tržišta ili IoT okruženja, brzina odlučivanja predstavlja značajnu konkurentsku prednost. Savremeni sistemi zasnovani na podacima koriste streaming platforme poput distribuiranih platforma za prenos podataka u realnom vremenu (*engl. Apache Kafka*), alate za obradu podataka u realnom vremenu (*engl. Spark Streaming*) te API interfejse (*engl. Application Programming Interface – API*) modela mašinskog učenja, koji omogućavaju automatizovanu analizu i donošenje odluka. Ovakvi sistemi omogućavaju organizacijama prelazak sa reaktivnog na proaktivno upravljanje poslovnim procesima.

3.3. Izazovi i ograničenja

Uprkos značajnim prednostima, rezultati istraživanja ukazuju na niz izazova koji mogu ograničiti efikasnost primjene prediktivne analitike. Jedan od najčešćih problema odnosi se na pogrešno tumačenje rezultata modela. Prediktivni modeli ne garantuju apsolutnu tačnost, već generišu procjene zasnovane na vjerovatnoćama. Neadekvatna interpretacija rezultata može dovesti do pogrešnih poslovnih odluka, precjenjivanja pouzdanosti modela i zanemarivanja eksternih faktora koji utiču na poslovno okruženje. Dodatni izazov predstavlja prekomjerno oslanjanje na automatizovane analitičke sisteme, što može smanjiti značaj ljudske prosudbe u procesu odlučivanja. U takvim situacijama organizacije mogu donositi odluke isključivo na osnovu rezultata modela, bez kritičke evaluacije i razumijevanja šireg konteksta. Ovaj problem posebno je izražen kod tzv. „black box“ sistema (modeli čiji način donošenja odluka nije lako interpretirati), karakterističnih za složene algoritme mašinskog učenja, kod kojih je otežano objasniti način donošenja odluka. Posljedica toga može biti smanjena transparentnost sistema i povećan rizik od sistemskih grešaka. Implementacija prediktivne analitike zahtijeva interdisciplinarna znanja iz oblasti statistike, matematike, programiranja i domenskog poslovnog razumijevanja. Posebno se ističe značaj programskih jezika i platformi za obradu podataka, poput Python okruženja (*engl. Python Environment*) i R okruženja (*engl. R Environment*), koji omogućavaju razvoj analitičkih modela i statističku obradu podataka. Nedostatak kvalifikovanih stručnjaka predstavlja značajnu prepreku, naročito u manjim organizacijama koje nemaju razvijenu analitičku infrastrukturu. Pored tehničkih izazova, pojedina istraživanja ukazuju i na etičke probleme povezane sa zaštitom privatnosti podataka, algoritamskom pristrasnošću i transparentnošću automatizovanih sistema odlučivanja (Dwivedi et al., 2023). Ovi problemi posebno dolaze do izražaja u sektorima koji obrađuju osjetljive podatke, poput finansija i zdravstva.

3.4. Sinteza rezultata

Integracijom svih nalaza može se zaključiti da prediktivna analitika ima značajan transformacioni uticaj na savremeno poslovanje. Njena vrijednost proizlazi iz sposobnosti povezivanja podataka sa procesima strateškog odlučivanja, smanjenja neizvjesnosti i unapređenja efikasnosti i održivosti poslovnih procesa. Međutim, uspješna implementacija prediktivne analitike zavisi od više faktora, uključujući kvalitet i dostupnost podataka, adekvatan izbor i validaciju modela, stručnost kadrova i odgovorno upravljanje podacima i algoritmima. Na osnovu provedenog istraživanja može se zaključiti da prediktivna analitika donosi značajne ekonomske i poslovne koristi, uključujući smanjenje troškova, optimizaciju resursa i unapređenje procesa donošenja odluka. Istovremeno, njena efikasna primjena zahtijeva balans između tehnoloških rješenja i ljudske prosudbe, kao i kontinuirano praćenje etičkih i organizacijskih aspekata implementacije.

4. DISKUSIJA

Na osnovu prethodno iznesenih nalaza može se zaključiti da prediktivna analitika ima značajan potencijal za transformaciju savremenih poslovnih procesa. Međutim, njena efikasnost zavisi od kvaliteta implementacije, dostupnosti i pouzdanosti podataka, kao i sposobnosti organizacije da integriše tehnološke alate sa ljudskom ekspertizom i postojećim poslovnim procesima.

3.1. Prednosti primjene prediktivne analitike

Jedna od ključnih prednosti prediktivne analitike jeste njena sposobnost smanjenja neizvjesnosti u procesu donošenja odluka. Tradicionalni modeli menadžmenta uglavnom su se oslanjali na iskustvo, intuiciju i heurističke pristupe, dok savremeni analitički sistemi omogućavaju kvantifikaciju vjerovatnoća i simulaciju različitih poslovnih scenarija. Primjena prediktivne analitike omogućava organizacijama da anticipiraju tržišne trendove, unaprijede planiranje i alokaciju resursa te povećaju preciznost strateških odluka kroz analizu velikih skupova podataka. Na primjer, kompanije poput Amazon (Chen et al., 2012) koriste prediktivne modele za optimizaciju korisničkog iskustva, dok Siemens (IBM, 2023) primjenjuje analitičke sisteme radi povećanja efikasnosti industrijskih procesa. Navedeni primjeri potvrđuju da prediktivna analitika nije samo tehnički alat, već strateški resurs koji organizacijama omogućava ostvarivanje konkurentske prednosti i diferencijaciju na tržištu.

3.2. Izazovi i ograničenja

Uprkos brojnim prednostima, implementacija prediktivne analitike suočava se sa nizom izazova koji mogu značajno uticati na njenu efikasnost. Savremeni algoritmi, posebno modeli zasnovani na dubokom učenju, često funkcionišu kao black box modeli kod kojih je otežano razumijevanje načina na koji algoritam generiše određene odluke ili preporuke. Nedostatak transparentnosti može predstavljati ozbiljan problem u kontekstu odgovornog i regulatorno usklađenog odlučivanja. U sektorima poput finansija i zdravstva, gdje odluke mogu imati značajne posljedice, otežana interpretacija modela može dovesti do smanjenog povjerenja u sistem, regulatornih problema i otežane validacije odluka. Dodatni izazov odnosi se na kvalitet podataka korištenih za treniranje modela. Ukoliko podaci sadrže greške, nedosljednosti ili algoritamske pristrasnosti (*engl. Bias*), modeli mogu reprodukovati i

dodatno intenzivirati postojeće probleme, što može negativno uticati na pouzdanost rezultata i kvalitet poslovnih odluka.

3.3. Rizici primjene prediktivne analitike

Jedan od najznačajnijih rizika primjene prediktivne analitike jeste pogrešno razumijevanje rezultata analitičkih modela. Prediktivni modeli ne generišu apsolutno tačne rezultate, već procjene zasnovane na vjerovatnoćama i statističkim obrascima. Menadžeri bez adekvatnog analitičkog znanja mogu pogrešno interpretirati rezultate modela, donositi odluke bez razumijevanja ograničenja analitičkih sistema i zanemariti kontekstualne faktore koji nisu obuhvaćeni modelom. Ovaj problem posebno dolazi do izražaja kada postoji komunikacijski jaz između tehničkih timova i menadžmenta. Pored toga, prekomjerna automatizacija odlučivanja može dovesti do smanjenja kritičkog razmišljanja i pretjeranog oslanjanja na tehnološke sisteme (Dwivedi et al., 2023). U takvim situacijama organizacije rizikuju smanjenu adaptivnost u kompleksnim poslovnim okruženjima, donošenje odluka koje nisu kontekstualno optimalne te brzo širenje sistemskih grešaka kroz automatizovane procese.

3.4. Preporuke za uspješnu implementaciju

Na osnovu identifikovanih prednosti, izazova i rizika, moguće je definisati ključne preporuke za organizacije koje žele implementirati prediktivnu analitiku na održiv i efikasan način. Najefikasniji pristup donošenju odluka nije ni potpuno automatizovan ni isključivo zasnovan na intuiciji, već podrazumijeva hibridni model odlučivanja. U takvom modelu prediktivni sistemi generišu preporuke i analitičke uvide, dok menadžeri donose konačne odluke uzimajući u obzir širi poslovni i društveni kontekst. Ovakav pristup omogućava kombinaciju brzine i preciznosti tehnologije sa iskustvom, intuicijom i kritičkim razmišljanjem ljudi. Uvođenje prediktivne analitike zahtijeva i razvoj novih kompetencija unutar organizacije. Posebno se ističe značaj razvoja kompetencija podatkovne pismenosti (*engl. Data Literacy*), odnosno sposobnosti razumijevanja, interpretacije i korištenja podataka u poslovnom odlučivanju, kao i osnovnog poznavanja statistike i modela mašinskog učenja. Pored tehničkih i organizacionih aspekata, etička pitanja predstavljaju jedan od ključnih izazova implementacije prediktivne analitike. Organizacije moraju osigurati transparentnost modela, zaštitu privatnosti podataka i pravednost u procesu donošenja odluka. OECD (2021) ističe da razvoj umjetne inteligencije značajno transformiše tržište rada i zahtijeva kontinuirano unapređenje kompetencija zaposlenih.

4. ZAKLJUČAK

U ovom radu analizirana je uloga prediktivne analitike kao značajnog elementa savremenog poslovanja, s posebnim fokusom na njen doprinos održivosti i strateškom odlučivanju. Integracijom teorijskog okvira, metodološkog pristupa, analize literature i studija slučaja, istraživanje ukazuje da prediktivna analitika predstavlja važan faktor digitalne transformacije organizacija u 21. vijeku. Prema izvještaju Svjetskog ekonomskog foruma (*engl. World Economic Forum – WEF*, 2023), analitičke i AI (*engl. Artificial Intelligence – AI*) kompetencije postaju jedan od ključnih faktora konkurentnosti savremenih organizacija.

Rezultati istraživanja ukazuju da prediktivna analitika omogućava organizacijama prelazak sa tradicionalnog, reaktivnog modela upravljanja na proaktivni, data-driven pristup donošenju odluka. Primjenom statističkih modela, algoritama mašinskog učenja i infrastrukture velikih podataka, organizacije mogu procjenjivati vjerovatne buduće trendove i poslovne ishode, optimizovati poslovne procese i smanjiti neizvjesnost u donošenju odluka. Na taj način prediktivna analitika doprinosi unapređenju efikasnosti, konkurentnosti i dugoročne stabilnosti poslovanja. Posebno je značajno naglasiti da ekonomske i poslovne koristi prediktivne analitike - uključujući smanjenje troškova, optimizaciju resursa i unapređenje upravljanja rizicima - u velikom broju slučajeva nadmašuju izazove povezane sa implementacijom. Međutim, ostvarivanje ovih koristi zavisi od organizacionog konteksta i kvaliteta implementacije. Uspješna primjena prediktivne analitike zahtijeva kvalitetne i dostupne podatke, adekvatan izbor i validaciju modela, stručan kadar te sposobnost organizacije da analitičke alate integriše u postojeće poslovne procese. Prediktivna analitika ostvaruje najveći efekat u organizacijama koje primjenjuju strateški i odgovoran pristup upravljanju podacima i analitičkim modelima. Organizacije koje zanemare ove aspekte mogu biti izložene rizicima poput pogrešne interpretacije rezultata, prekomjerne zavisnosti od tehnologije i potencijalnih etičkih problema povezanih sa privatnošću podataka i transparentnošću algoritama. U kontekstu održivog poslovanja, prediktivna analitika ima posebno značajnu ulogu jer omogućava racionalnije korištenje resursa, smanjenje negativnog uticaja na okoliš i donošenje odluka koje uzimaju u obzir dugoročne posljedice poslovnih aktivnosti. Na taj način uspostavlja se direktna veza između digitalne transformacije i održivog razvoja, pri čemu tehnologija postaje sredstvo za stvaranje šire društvene i ekonomske vrijednosti. Perspektive budućeg razvoja ukazuju da će prediktivna analitika imati sve značajniju ulogu u oblikovanju savremenih poslovnih modela. Razvoj vještačke inteligencije, automatizacije i analitike u realnom vremenu dodatno će unaprijediti sposobnost organizacija da donose brze i precizne odluke. Istovremeno, očekuje se jačanje regulatornih okvira i etičkih standarda, što će zahtijevati veću transparentnost, odgovornost i sigurnost u korištenju podataka i analitičkih modela.

LITERATURA

1. **Accenture.** (2023). *Powering sustainable AI.* Accenture. Preuzeto sa https://www.accenture.com/us-en/insights/sustainability/powering-sustainable-ai Pristupljeno 19.05.2026.
2. **Adesina, A. A., Iyelolu, T. V., & Paul, P. O.** (2024). *Leveraging predictive analytics for strategic decision-making.* World Journal of Advanced Research and Reviews, *22*(3), 1927–1934.
3. **Chen, H., Chiang, R. H. L., & Storey, V. C.** (2012). *Business intelligence and analytics: From big data to big impact.* MIS Quarterly, *36*(4), 1165–1188.
4. **Davenport, T. H., & Harris, J. G.** (2007). *Competing on Analytics: The New Science of Winning.* Harvard Business Review Press.
5. **Dwivedi, Y. K., et al.** (2023). *So what if ChatGPT wrote it? Multidisciplinary perspectives on opportunities, challenges and implications of generative*

conversational AI for research, practice and policy. International Journal of Information Management, 71, Article 102642.

6. **Gandomi, A., & Haider, M.** (2015). *Beyond the hype: Big data concepts, methods, and analytics.* International Journal of Information Management, 35(2), 137–144.
7. **Gartner.** (2024). *Gartner Top Strategic Technology Trends 2024.* Gartner, Inc. Preuzeto sa https://www.gartner.com/en/newsroom/press-releases/2023-10-16-gartner-identifies-the-top-10-strategic-technology-trends-for-2024 Pristupljeno 19.05.2026.
8. **Gomez-Uribe, C. A., & Hunt, N.** (2015). *The Netflix recommender system: Algorithms, business value, and innovation.* ACM Transactions on Management Information Systems, 6*(4), 1–19.*
9. **IBM.** (2023). *IBM Global AI Adoption Index 2023.* IBM Corporation. Preuzeto sa https://newsroom.ibm.com/2024-01-10-Data-Suggests-Growth-in-Enterprise-Adoption-of-AI-is-Due-to-Widespread-Deployment-by-Early-Adopters Pristupljeno 19.05.2026.
10. **Jamarani, A., Haddadi, S., Sarvizadeh, R., et al.** (2024). *Big data and predictive analytics: A systematic review of applications.* Artificial Intelligence Review, 57, 176.
11. **Lee, J., Bagheri, B., & Kao, H. A.** (2014). *A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems. Manufacturing Letters, 3*, 18–23.
12. **OECD.** (2021). *The impact of artificial intelligence on the labour market.* OECD Publishing.
13. **McKinsey Global Institute.** (2023). *The economic potential of generative AI: The next productivity frontier.* McKinsey & Company. Preuzeto sa https://www.mckinsey.com/capabilities/tech-and-ai/our-insights/the-economic-potential-of-generative-ai-the-next-productivity-frontier#/ Pristupljeno 19.05.2026.
14. **Porter, M. E.** (1985). *Competitive Advantage: Creating and Sustaining Superior Performance.* Free Press.
15. **Raghupathi, W., & Raghupathi, V.** (2014). *Big data analytics in healthcare: promise and potential.* Health Information Science and Systems, 2(3).
16. **Shmueli, G., Bruce, P. C., Gedeck, P., & Patel, N. R.** (2020). *Data Mining for Business Analytics: Concepts, Techniques, and Applications in Python.* Wiley.
17. **World Economic Forum.** (2023). *The Future of Jobs Report 2023.* Geneva: World Economic Forum. Preuzeto sa https://www.weforum.org/publications/the-future-of-jobs-report-2023/ Pristupljeno 19.05.2026.