

Pregledni znanstveni članak

■ Potencijal primjene umjetne inteligencije u osiguranju

Mihovil Anđelinović¹

Sažetak: Razvoj tehnologije i sve veće mogućnosti umjetne inteligencije transformiraju način na koji organizacije posluju. U sektoru osiguranja, umjetna inteligencija uvodi revoluciju u tradicionalno poslovanje, mijenjajući procese - počevši od procjene rizika, preko razvoja proizvoda, do komunikacije s klijentima. Osim toga, umjetna inteligencija pruža brojne mogućnosti u analizi podataka i donošenju prediktivnih odluka. Cilj ovog rada je istražiti mogućnosti primjene umjetne inteligencije u industriji osiguranja, proučavajući njen potencijal za različite aspekte poslovanja i funkcijske jedinice, a imajući na umu i regulatorna ograničenja i smjer razvoja tehnologija. Kroz usvajanje novih tehnologija, društva za osiguranje unaprjeđuju svoje poslovanje, smanjuju rizike te rade zaokret u pristupu klijentima kroz personalizaciju, što rezultira značajnom transformacijom pristupa pružanju usluge. Iako je umjetna inteligencija već inkorporirana u lanac vrijednosti u ovoj industriji, uspon generativne umjetne inteligencije sugerira da njezin puni potencijal tek treba biti ostvaren.

Cljučne riječi: umjetna inteligencija, osiguranje, tehnologija, digitalizacija

1. UVOD

U posljednjem je desetljeću rapidan razvoj tehnologije, a posebno područja umjetne inteligencije (engl. *Artificial Intelligence*, AI, nadalje: UI), transformirao način na koji organizacije posluju. Umjetna inteligencija, kao ključna tehnološka inovacija, sa sobom donosi obećanje dubokih promjena u poslovnom svijetu, pritom najviše u industrijama koje su tradicionalno sklone inovacijama. U tom kontekstu, financijski sektor predstavlja idealno područje za usvajanje UI tehnologija. Umjetna inteligencija u financijama, posebno algoritmi strojnog učenja, optimizira zadatke poput analize podataka, prognoziranja, upravljanja investicijama i rizicima, otkrivanja prijevara i korisničke podrške. Nadalje, modernizira financijske usluge automatizacijom procesa, pruža uvide

¹ izv. prof. dr. sc. Mihovil Anđelinović, Sveučilište u Zagrebu, Ekonomski fakultet, Trg J. F. Kennedyja 6, 10000 Zagreb, e-mail: mandelinovic@efzg.hr

u tržišta te omogućuje interakcije s korisnicima koje simuliraju ljudsku inteligenciju. Također, revolucionira financijske operacije, brzo i precizno izvršavajući transakcije, poboljšavajući upravljanje rizicima i predviđajući ponašanje korisnika radi personalizirane interakcije (IBM, 2024), dodajući novu dimenziju financijskom sustavu.

Dok neki sektori, poput bankarstva, već godinama ulažu u umjetnu inteligenciju (McKinsey & Company, 2017), istraživanja pokazuju da je tehnologija umjetne inteligencije u sektoru osiguranja usvojena nešto kasnije (Accenture, 2020). Umjetna inteligencija mijenja način na koji osiguratelji posluju, donose odluke i komuniciraju sa svojim klijentima. Uz brigu o društvenim vrijednostima i prilagodbu promjenjivim potrebama korisnika, transformacijski potencijal umjetne inteligencije prepoznat je kao vodeći trend svjetske industrije osiguranja u ovoj godini (EY, 2024). Prema njihovim studijama, 58% predsjednika uprava društava za osiguranje ima pozitivan pogled na ulogu umjetne inteligencije, a njih 52% planira značajne investicije u umjetnu inteligenciju u 2024. godini. S druge strane, više od 60% korisnika osjeća se ugodno kada se umjetna inteligencija koristi za sigurnost zajednice, otkrivanje kriminala i povećanje učinkovitosti na radnom mjestu (EY, 2023a, 2023b). Primjena tehnologija umjetne inteligencije moguća je kroz cijeli lanac vrijednosti osiguranja (Riikkinen i sur., 2018; Singh i Chivukula, 2020; Eling i sur., 2022; Zhang i sur., 2023), uključujući razvoj proizvoda, upravljanje štetama, interakciju s klijentima te različite druge primjene u primarnim i potpornim aktivnostima.

Iako postoji opća suglasnost u znanstvenoj i stručnoj zajednici o potencijalu umjetne inteligencije da transformira ovaj sektor, pitanje rizika i ograničenja umjetne inteligencije izaziva kontroverze. U tom kontekstu, istraživanje primjene umjetne inteligencije u osigurateljskom sektoru postaje sve važnije. Ovaj rad ima za cilj dati sveobuhvatan pregled primjene umjetne inteligencije u ovom sektoru, istaknuti mogućnosti koje ta tehnologija pruža te predvidjeti njezin očekivani razvoj. Nadalje, fokus će biti stavljen na identifikaciju i analizu rizika koji proizlaze iz korištenja umjetne inteligencije u osiguranju, kao i na ulogu regulative u rješavanju tih izazova.

Rad je strukturiran na sljedeći način: u drugom dijelu proučavaju se načini integracije umjetne inteligencije u funkcijske jedinice društava za osiguranje, uz odabrane primjere njezine primjene. Treći dio istražuje smjerove razvoja umjetne inteligencije, naglašavajući aspekte koji se trebaju uzeti u obzir za daljnji napredak, uključujući regulatorne prepreke i moguće rizike. Četvrti dio predstavlja zaključak rada.

2. UTJECAJ UMJETNE INTELIGENCIJE NA PROCESU U OSIGURANJU

Digitalizacija industrije osiguranja značajno je napredovala, potaknuta tzv. *InsurTechom* i nizom tehnologija kao što su računarstvo u oblaku (engl. *cloud computing*), internet stvari (engl. *Internet of Things, IoT*) (Riikkinen i sur., 2018) i umjetna inteligencija. Ova integracija dovela je do poboljšane učinkovitosti procesa, preuzimanja rizika i razvoja proizvoda, uz nove poslovne modele. U početku usmjerena na online distribucijske kanale, digitalizacija se proširila sa širom uporabom mobilnih uređaja za ovu svrhu, omogućujući društvima za osiguranje da iskoriste iznimne količine podataka o klijentima. Aplikacije umjetne inteligencije, ukorijenjene u desetljećima razvoja, oslanjaju se na te podatke za prepoznavanje obrazaca i donošenje informiranih odluka. Iako se definicije umjetne inteligencije razlikuju, ona općenito uključuje dizajniranje inteligentnih sustava sposobnih za zadatke poput ljudskih (Barr i Feigenbaum, 1981; McCarthy, 2007). Usvajanje ovih tehnologija transformiralo je industriju, poboljšavajući njezinu učinkovitost i performanse u različitim funkcijama (Eling i sur., 2022).

Neki primjeri primjene UI u osigurateljnem sektoru su široko poznati, kao što su detekcija prijevara ili virtualni asistenti (tzv. *chatbotovi*). Umjetna inteligencija je širok pojam koji se odnosi na tehnologiju s mogućnošću učenja. Strojno učenje (engl. *machine learning, ML*) i duboko učenje (engl. *deep learning, DL*), gdje učenje može biti nadgledano ili nenadgledano, čine UI sposobnijom i dostupnijom organizacijama. Postoji spektar mogućnosti UI i spektar stupnjeva njene implementacije. Kako se sposobnija UI implementira duž lanca vrijednosti, potrebno je više podataka i promjena većeg broja procesa. Neke organizacije ne mogu napraviti ovu transformaciju jer im nedostaju potrebni podaci ili nisu spremne promijeniti svoje procese (Zarifis i sur., 2023), što sugerira da će trebati implementirati nove poslovne modele kako bi iskoristile potencijal umjetne inteligencije.

Kako bi se detaljno istražila primjena UI u osiguranju, koristan je teorijski okvir koji omogućuje sustavnu analizu ključnih aktivnosti organizacije. Jedan od najpriznatijih teorijskih pristupa za prikaz ključnih aktivnosti organizacije je Porterov (1985) lanac vrijednosti. Slika 1. prikazuje njegovu primjenu u sektoru osiguranja. Porterov lanac vrijednosti razlikuje primarne aktivnosti organizacije od potpornih aktivnosti u proizvodnji proizvoda ili pružanju usluga. Kako Porterov lanac nije specifično formuliran za industriju osiguranja, prikazuje se prilagođena verzija prema Rahlfsu (2007) te Elingu i suradnicima (2022).

Slika 1: Lanac vrijednosti u osiguranju

Primarne aktivnosti	Razvoj proizvoda	Prodaja i marketing	Preuzimanje rizika	Korisnička podrška i izdavanje polica osiguranja	Upravljanje štetama	Upravljanje rizicima (i imovinom)
	Upravljanje					
Potporne aktivnosti	Informatička tehnologija					
	Ljudski resursi					
	Kontroling					
	Pravni odjel					
	Odnosi s javnošću					
	Informatička tehnologija					

Izvor: Izrada autora prema Rahlfsu (2007) i Elingu i suradnicima (2022)

Kao što pokazuje Slika 1., primarne aktivnosti u osiguranju obuhvaćaju sve aktivnosti koje su izravno povezane s pružanjem usluga osiguranja, kao što su prikupljanje informacija o klijentima i rizicima, procjena rizika, izdavanje polica, upravljanje štetama i pružanje usluga korisnicima nakon prodaje. Ove aktivnosti čine srž poslovanja društava za osiguranje. S druge strane, potporne aktivnosti uključuju sve procese i funkcije koje podržavaju primarne aktivnosti, poput ljudskih resursa i informatičke službe. Tablica 1. razrađuje primjenu umjetne inteligencije i novih tehnologija u primarnim aktivnostima osiguranja.

Tablica 1: Primjena UI i novih tehnologija u primarnim aktivnostima u osiguranju

Aktivnost	Područja primjene
Razvoj proizvoda	<ul style="list-style-type: none"> - uporaba dronova i interneta stvari (engl. <i>Internet of Things, IoT</i>) kao što su oni koji prate obrasce vožnje ili zdravlje za kreiranje prilagođenih osigurateljnih proizvoda - obrada slika, analiza teksta, obrada prirodnog jezika (NLP), razumijevanje prirodnog jezika (NLU) i generiranje prirodnog jezika (NLG) mogu pomoći u razvoju proizvoda

Prodaja i marketing	<ul style="list-style-type: none"> - razvoj prediktivnih modela za pronalaženje klijenata različitim metodama strojnog učenja (SVM) i statističke analize (npr. CHAID, HC) - pronalaženje novih klijenata putem geoprostorne (GIS) analize - segmentacija klijenata pomoću multinomijalne logističke regresije i drugih hibridnih modela koji kombiniraju različite algoritme klasifikacije i klasteriranja - uporaba strojnog učenja za predviđanje odljeva klijenata i životne vrijednosti klijenata - uporaba UI za prepoznavanje životnih događaja kod kojih će klijenti trebati osiguranje
Preuzimanje rizika (engl. <i>underwriting</i>)	<ul style="list-style-type: none"> - automatizacija procesa preuzimanja rizika uporabom strojnog učenja i statističkih metoda poput <i>fuzzy</i> logike i obrade prirodnog jezika (NLP) - proširenje raspona osigurljivih rizika, olakšano automatiziranim procjenom rizika i kontinuiranim nadzorom - bolje predviđanje potencijalne prijevare
Korisnička podrška i izdavanje polica osiguranja	<ul style="list-style-type: none"> - individualizirana usluga temeljena na algoritmima strojnog učenja korištenim za analizu podataka o korisnicima - tzv. chatbotovi, digitalni osobni asistenti i tehnike prepoznavanja govora pomažu boljem razumijevanju potreba klijenata - mogućnost prepoznavanja osjećaja klijenata - poboljšano savjetovanje klijenata
Upravljanje štetama	<ul style="list-style-type: none"> - predviđanje stope odštetnih zahtjeva - brže i preciznije rješavanje zahtjeva
Upravljanje rizicima	<ul style="list-style-type: none"> - optimizacija upravljanja rizicima

Izvor: Porter (1985), Rahlfs (2007), Singh i Chivukula (2020), Eling i suradnici (2022), Zarifs i suradnici (2023)

Tablica 1. daje pregled primarnih aktivnosti koje osiguratelji obavljaju, zajedno s područjima primjene umjetne inteligencije i novih tehnologija

kod svake od tih aktivnosti. Primjena UI donosi različite prednosti, uključujući poboljšanu učinkovitost, personalizaciju usluga, brže i preciznije odluke te bolje razumijevanje potreba i preferencija klijenata. U fazi razvoja proizvoda, umjetna inteligencija olakšava stvaranje inovativnih osigurateljnih proizvoda koji su prilagođeni novim skupinama klijenata i nastalim rizicima. Analizom njihovog ponašanja i povratnih informacija, osiguratelji mogu poboljšati postojeće ponude i razviti proizvode prilagođene individualnim potrebama, čime se dodatno povećava angažman i lojalnost klijenata (Eling i sur., 2022). Kod prodaje i marketinga, implementacija umjetne inteligencije vodi do ušteda kroz manje aktivnog uključivanja prodajnih agenata, dok *chatbotovi* proaktivno pristupaju klijentima s prilagođenim ponudama proizvoda.

Automatizacija, kao jedna od najvećih prilika umjetne inteligencije optimizira procese kod preuzimanja rizika i upravljanja štetama, dovodeći do ušteda i preciznijih odluka na temelju sve većeg broja dostupnih podataka osigurateljima. Automatizirana obrada šteta povećava točnost i učinkovitost, smanjujući ljudski angažman i ubrzavajući isplate šteta. U fazi korisničke podrške i izdavanja polica osiguranja, umjetna inteligencija pomaže u usklađivanju upita klijenata s najkvalificiranijim dostupnim agentom i nudi automatiziranu korisničku podršku putem *chatbotova* (Eling i sur., 2022). Ovo personalizirano iskustvo povećava zadovoljstvo klijenata, a mogućnost personalizacije je ujedno i jedna od najvećih prednosti uporabe umjetne inteligencije.

Uz primjenu u primarnim aktivnostima, UI i povezane tehnologije mogu se upotrijebiti i u potpornim aktivnostima osiguratelja. To uključuje automatizaciju jednostavnih, ali repetitivnih zadataka radi optimizacije administrativnih procesa, učinkovito procesiranje velikih količina podataka te poboljšanje kvalitete skupova podataka korištenih za donošenje odluka. Nadalje, UI omogućuje korištenje podataka s IoT uređaja za dinamične uvjete osiguranja i podržava analize pružajući im virtualne asistente za dosljednu analizu. Također, UI identificira i analizira nove izvore podataka te podržava procese revizije pružajući dublje uvide. Sveukupno, UI revolucionira procese osiguranja optimizacijom procesiranja podataka, poboljšanjem upravljanja rizicima te povećanjem učinkovitosti (Zarifis i sur., 2023).

U narednim godinama očekuje se da će UI omogućiti gotovo trenutačno izdavanje polica s minimalnim angažmanom osiguratelja i klijenta, uz precizne profile rizika koje stvaraju UI algoritmi. Pametni ugovori omogućit će trenutačne autorizacije plaćanja, dok će se procesi poput procjene i verifikacije plaćanja svesti na minimum ili potpuno eliminirati, smanjujući troškove akvizicije za osiguratelje. U području obrade šteta, očekuje

se da će više od polovice aktivnosti biti automatizirano uz uporabu naprednih algoritama, IoT senzora i raznih tehnologija za prikupljanje podataka. Upozorenja i intervencije u realnom vremenu (engl. *real-time*) unaprijedit će sustave izbjegavanja gubitaka, dok će osiguratelji koristiti integrirane IoT, telematiku i mobilne podatke za procjene velikih šteta u slučaju katastrofa, osiguravajući brže i točnije procjene gubitaka i protok kapitala (McKinsey & Company, 2021).

Stupanj usvajanja novih tehnologija kod osiguratelja ovisit će o njihovim potrebama, spremnosti na promjene i strukturi poslovnog modela, kao i dostupnosti tehnologija. No, osim faktora spremnosti društava na promjene i sposobnosti umjetne inteligencije, treba uzeti u obzir i klijente. Većina trenutnih primjena UI jača sposobnosti osiguratelja, ali ne i klijenata, što povećava problem asimetrije informacija. Kako se ta asimetrija povećava, klijenti mogu biti u slabijem položaju (Zarifis i sur., 2023), što zahtijeva razmatranje načina kako ih kompenzirati ili pružiti dodatne koristi. Ovaj faktor potencijalno mijenja dinamiku odnosa između osiguratelja i klijenata, što može imati značajan utjecaj na poslovne modele u industriji osiguranja. To je jedno od područja gdje uloga regulacije dolazi do izražaja.

3. REGULATORNA OGRANIČENJA I POTENCIJALNI RIZICI PRIMJENE UMJETNE INTELIGENCIJE

Regulatori diljem svijeta aktivno se bave smjernicama i inicijalnim zakonodavstvom u vezi s usvajanjem umjetne inteligencije, potaknuti širokom dostupnošću aplikacija generativne UI od 2022. godine. Rasprostranjeno usvajanje generativne umjetne inteligencije od strane društava za osiguranje još uvijek je u ranoj fazi, ali osiguratelji aktivno istražuju njene potencijalne upotrebe, kao što je pružanje savjeta potrošačima, vođenje osiguranika kroz postupke odštetnih zahtjeva i poboljšanje procesa određivanja cijena i osiguranja (EIOPA, 2024).

Pojavile su se zajedničke teme za regulatore kao što su transparentnost i objašnjivost u dizajnu modela i rezultatima, pri čemu su se mnogi oslanjali na postojeće regulatorne režime. Naponi organizacija poput OECD-a, UNESCO-a i G7 usmjereni su na koordinaciju odgovora i promicanje upravljanja s UI usklađenog s demokratskim vrijednostima, uključujući uspostavu Hirošimskog procesa umjetne inteligencije kao foruma za suradnju (EY, 2024).

Nadalje, očekuje se da će SAD postupati sporo s uvođenjem ograničene regulacije, dok se europski osiguratelji pripremaju za sveobuhvatno

zakonodavstvo prema Uredbi Europske komisije o umjetnoj inteligenciji ili Aktu o umjetnoj inteligenciji (EU 2024/0138) (Europska unija, 2024).

Akt o umjetnoj inteligenciji je ujedno i prvi pravni okvir koji se bavi rizicima umjetne inteligencije (Europska komisija, 2024). Ključni aspekti akta su usklađeni standardi, pristupi temeljeni na riziku i alati za usklađivanje, posebno za visokorizične sustave UI. Akt ima posebne implikacije za sektor osiguranja. Prvo, njegov "horizontalni" pristup s ciljem obuhvata svih relevantnih sektora istovremeno može izazvati poteškoće pri integraciji njegovih odredbi u visoko reguliranim i nadziranim sektorima kao što je osigurateljni sektor. Drugo, Akt predviđa usklađene standarde koje razvijaju europske organizacije za normizaciju, te pružanje smjernica i alata za usklađivanje kako bi se pomoglo pružateljima i korisnicima u ispunjavanju zahtjeva. Treće, primjenom pristupa temeljenog na riziku, većina zahtjeva Akta odnosi se na sustave UI koji su identificirani kao visokorizični. No, budući učinak Akta o umjetnoj inteligenciji u sektoru osiguranja ovisi o ishodu trijaloga i bit će potreban razvoj smjernica za njegovu učinkovitu provedbu (EIOPA, 2024).

Umjetna inteligencija donosi značajne dobrobiti osigurateljima, uključujući povećanu operativnu učinkovitost, manje troškove, unaprijeđenje korisničkog iskustva te naprednu prediktivnu inteligenciju. Međutim, rizici - kako financijski, tako i drugi - jednako su važni kao i potencijalne koristi i usko su povezani. Tablica 2. daje pregled najvažnijih rizika i ograničenja primjene umjetne inteligencije u osiguranju.

Tablica 2: Rizici i ograničenja umjetne inteligencije u osiguranju

Rizik	Pojava
Povjerljivost podataka	Glavni tehnološki rizik je povjerljivost podataka. UI omogućava prikupljanje i obradu informacija u velikim razmjerima, što može rezultirati curenjem podataka. Generativna UI je dodatna prijetnja jer stvara novi sadržaj na temelju tih podataka, čime se povećava rizik od njihovog otkrivanja.

Strah od gubitka privatnosti	Kontinuirani nadzor, primjerice putem telematike i prijenosnih uređaja, može se smatrati invazivnim i izazvati zabrinutost kod klijenata zbog osjećaja stalnog nadzora.
Sigurnost	U slučaju curenja algoritma UI, treća strana može kopirati model, što može rezultirati ekonomskim i gubitkom intelektualnog vlasništva društva.
Transparentnost	Karakteristika crne kutije UI posebno generativne umjetne inteligencije, čini proces odlučivanja algoritama umjetne inteligencije teško razumljivim, što može biti problem za visoko regulirani sektor osiguranja koji počiva na povjerenju.
Netočni ili pristrani podaci kao baza sustava	Uspjeh UI-a uvelike ovisi o kvaliteti podataka koje koristi za učenje. Ako je sustav obučen na netočnim, pristranim ili plagiranim podacima, rezultat će neželjenim ishodima unatoč tome što je tehnički dobro dizajniran.
Zlouporeba	Iako UI može pravilno obavljati analizu, donošenje odluka, koordinaciju i slične aktivnosti, postoji rizik od zlouporebe. Namjena operatora, metode korištenja, i opseg primjene mogu biti iskrivljeni ili manipulirani te rezultirati negativnim posljedicama.
Pretjerano oslanjanje na UI	Korisnici često teško procjenjuju razinu povjerenja u UI jer im nedostaje svijest o njenim sposobnostima, performansama i načinu rada, što može rezultirati donošenjem loših odluka.

Izvor: Svjetska banka (2023), Međunarodni monetarni fond (2024)

Ublažavanje rizika vezanih uz usvajanje UI zahtijeva višestrani pristup upravljanju koji se bavi tehničkim problemima i problemima uporabe. Za učinkovito upravljanje rizicima korištenja IBM (2024) predlaže sljedeća

tri koraka. Prvo, pokretanje opsežnog programa obuke koji će osigurati da je osoblje uključeno u razvoj, odabir ili korištenje UI dobro poznato s očekivanjima i smjernicama. Drugo, implementacija sheme procjene pružatelja UI alata omogućuje procjenu robusnosti i transparentnosti kontrola u ugovornim sporazumima. Konačno, uspostavljanje mjera za provedbu politike postavlja jasne norme, uloge, odgovornosti, procese odobravanja i smjernice za održavanje tijekom životnog ciklusa razvoja UI. Poboljšanje IT upravljanja ključno je za ublažavanje tehnoloških rizika. To uključuje proširenje taksonomije podataka i sustava kako bi se osiguralo da model obuhvaća potrebne ulaze, uzorke, provjere valjanosti i cikluse testiranja, uz smještaj na internim poslužiteljima. Nadalje, stvaranje registra rizika omogućuje kvantifikaciju utjecaja, razine ranjivosti i protokole praćenja. Na kraju, razvijanje opsežne analitičke i strategije testiranja olakšava redovito testiranje za praćenje rizika koji se odnose na ulaze, izlaze i komponente modela sustava UI.

Potencijal umjetne inteligencije u osiguranju leži u njegovoj sposobnosti izvlačenja novih uvida iz sve većih i složenijih skupova aktuarskih podataka i podataka o štetama. Međutim, osiguranje učinkovite i točne UI zahtijeva pedantnu znanost o podacima. Kako se tehnologije umjetne inteligencije razvijaju, a aplikacije šire, osiguratelji bi se trebali aktivno uključiti u razvoj tehnologije, koristeći svoju stručnost u području kako bi osigurali sigurnu i učinkovitu implementaciju umjetne inteligencije u sektoru osiguranja.

4. ZAKLJUČAK

U posljednjem desetljeću, rapidan razvoj tehnologije, osobito područja umjetne inteligencije, transformirao je način poslovanja organizacija, obećavajući duboke promjene u poslovnom svijetu, posebno u inovativnim industrijama poput financijskog sektora. Umjetna inteligencija u financijama optimizira zadatke poput analize podataka, prognoziranja i otkrivanja prijevara, donoseći automatizaciju procesa i pružajući uvide u tržišta. S druge strane, sektor osiguranja, iako nešto kasnije, također prepoznaje potencijal UI, s brojnim osigurateljima koji planiraju značajne investicije u ovu tehnologiju. No, iako postoji opća suglasnost o potencijalu UI za transformaciju ovog sektora, postoje i kontroverze vezane uz rizike i ograničenja te tehnologije. Stoga je istraživanje primjene UI postalo važno, a ovaj rad ima za cilj pružiti pregled i njenih mogućnosti u sektoru osiguranja.

Umjetna inteligencija, posebno strojno učenje i duboko učenje, olakšava stvaranje inovativnih osigurateljskih proizvoda. Primjena umjetne inteligencije proteže se kroz cijeli lanac vrijednosti osiguranja, uključujući

razvoj proizvoda, prodaju i marketing, preuzimanje rizika, korisničku podršku te upravljanje štetama i rizicima. Očekuje se da će umjetna inteligencija omogućiti brže i preciznije odluke, gotovo trenutačno izdavanje polica te automatizirane procese, smanjujući troškove i poboljšavajući kvalitetu usluge. Ipak, stupanj usvajanja novih tehnologija ovisi o potrebama osiguratelja, njihovoj spremnosti na promjene te strukturi poslovnog modela, dok asimetrija informacija između osiguratelja i klijenata može zahtijevati razmatranje dodatnih koristi ili kompenzacija za klijente. Ovaj razvoj također postavlja pitanja o ulozi regulacije u industriji osiguranja.

Regulatori diljem svijeta sve više se bave smjernicama i zakonodavstvom vezanim uz usvajanje umjetne inteligencije, potaknuti raširenošću generativne UI od 2022. godine. Napori regulatori usmjereni su na transparentnost i objašnjivost, a za područje EU najznačajniji je Akt o umjetnoj inteligenciji, prvi pravni okvir koji se bavi rizicima UI. Rizici primjene UI uključuju povjerljivost podataka, strah od gubitka privatnosti i sigurnost, dok je ključno za ublažavanje ovih rizika poboljšati IT upravljanje i uspostaviti mjere za provedbu politika. Potencijal umjetne inteligencije u osiguranju ogleda se u njezinoj sposobnosti izvlačenja novih uvida iz složenih podataka, ali zahtijeva pedantnu znanost o podacima i aktivno sudjelovanje osiguratelja u razvoju tehnologije.

Artificial intelligence in insurance: applications and implications

Summary: *The advancement of technology and the expanding capabilities of artificial intelligence are reshaping the way organizations operate. In the insurance sector, artificial intelligence is initiating a revolution in traditional practices, altering processes from risk assessment to product development and client communication. Furthermore, artificial intelligence provides numerous opportunities in data analysis and predictive decision-making. The aim of this study is to explore the potential applications of artificial intelligence in the insurance industry, examining its capacity across various business aspects and functional units, while considering regulatory constraints and the trajectory of technological advancements. By adopting new technologies, insurance companies enhance their operations, mitigate risks, and pivot towards personalized approaches in client interaction, resulting in a significant transformation in service delivery. While artificial intelligence has already been integrated into the value chain of this industry, the rise of generative artificial intelligence suggests that its full potential is yet to be realized.*

Keywords: *artificial intelligence, insurance, technology, digitization*

Navedeni izvori i korištena literatura

Accenture (2020), "Technology Vision for Insurance 2020." [Online]. Dostupno na: <https://www.accenture.com/content/dam/accenture/final/a-com-migration/pdf/pdf-120/accenture-technology-vision-for-insurance-2020-summary.pdf> (posjećeno 22.03.2024.)

Barr, A. i Feigenbaum, E.A. (1981), *The handbook of artificial intelligence*, Vol. 1. Stanford: Heuristic Tech Press.

EIOPA (2024), "AI Act and its impacts on the European financial sector." [Online]. Dostupno na: https://www.eiopa.europa.eu/publications/ai-act-and-its-impacts-european-financial-sector_en#details (posjećeno 12.04.2024.)

Eling, M., Nuessle, D. i Staubli, J. (2022), "The impact of artificial intelligence along the insurance value chain and on the insurability of risks," *Geneva Papers on Risk and Insurance: Issues and Practice*, 47, str. 205–241.

Europska komisija (2024), "Akt o umjetnoj inteligenciji," [Online]. Dostupno na: <https://digital-strategy.ec.europa.eu/hr/policies/regulatory-framework-ai> (posjećeno 14.04.2024.)

Europska unija (2024), Akt o umjetnoj inteligenciji. EU 2024/0138

EY (2023a), "CEO Outlook Pulse Survey, Global Report." [Online]. Dostupno na: https://assets.ey.com/content/dam/ey-sites/ey-com/en_gl/topics/ceo/ey-ceo-outlook-pulse-survey-july-2023-global-report.pdf (posjećeno 02.04.2024.)

EY (2023b), "Future Consumer Index, 2023." Dostupno na: https://www.ey.com/en_us/consumer-products-retail/have-ai-experiences-and-store-brands-lost-some-allure (posjećeno 02.04.2024.)

EY (2024), "Global Insurance Outlook: Strengthening trust to unlock innovation and growth." [Online]. Dostupno na: https://assets.ey.com/content/dam/ey-sites/ey-com/en_gl/topics/insurance/insurance-pdfs/ey-2024-global-insurance-outlook-report-v2.pdf (posjećeno 02.04.2024.)

IBM (2024), "What is Artificial Intelligence (AI) in Finance?" [Online]. Dostupno na: <https://www.ibm.com/topics/artificial-intelligence-finance> (posjećeno 22.03.2024.)

International Monetary Fund (2023), "Artificial Intelligence's Promise and Peril," [Online]. Dostupno na: <https://www.imf.org/en/Publications/fandd/issues/2023/12/B2B-Artificial-Intelligence-promise-peril-Tourpe> (posjećeno 11.04.2024.)

McCarthy, J. (2007), *What is artificial intelligence?* Stanford: Stanford University.

McKinsey & Company (2017), "Artificial Intelligence: The Next Digital Frontier?" [Online]. Dostupno na: <https://www.mckinsey.com/~media/mckinsey/industries/advanced%20electronics/our%20insights/how%20artificial%20intelligence%20can%20deliver%20real%20value%20to%20companies/mgi-artificial-intelligence-discussion-paper.ashx> (posjećeno 14.04.2024.)

McKinsey & Company (2021), "Insurance 2030 - The impact of AI on the future of insurance" [Online]. Dostupno na: <https://www.mckinsey.com/industries/financial-services/our-insights/insurance-2030-the-impact-of-ai-on-the-future-of-insurance> (posjećeno 10.04.2024.)

Porter, M. (1985), *The competitive advantage: Creating and sustaining superior performance*, New York: The Free Press.

Rahlf, C. (2007), *Redefinition der Wertschoepfungskette von Versicherungsunternehmen*, Wiesbaden: Deutscher Universitäts-Verlag.

Riikinen, M., Saarijärvi, H., Sarlin, P. i Lähteenmäki, I. (2018), "Using artificial intelligence to create value in insurance", *International Journal of Bank Marketing*, 36(6), 1145-1168.

Singh, S.K. i Chivukula, M. (2020), "A Commentary on the Application of Artificial Intelligence in the Insurance Industry," *Trends in Artificial Intelligence*, 4(1), str. 75-79.

Svjetska banka (2023), "Digital Progress and Trends Report 2023," [Online]. Dostupno na: <https://openknowledge.worldbank.org/server/api/core/bitstreams/95fe55e9-f110-4ba8-933f-e65572e05395/content> (posjećeno 11.04.2024.)

Zarifis, A., Holland, C. P. i Milne, A. (2023), "Evaluating the impact of AI on insurance: the four emerging AI- and data-driven business models", *Emerald Open Research*, 1(1).

Zhang, W., Shi, J., Wang, X. i Wynn, H. (2023), "AI-powered decision-making in facilitating insurance claim dispute resolution," *Annals of Operations Research*.

