HANFA
HRVATSKA AGENCIJA ZA NADZOR FINANCIJSKIH USLUGA

MAKROPRUDENCIJALNI SKENER RIZIKA

BROJ **XIV.** studeni 2026.

Drugo tromjesečje 2026.

(nelektorirana verzija)



Makroprudencijalni skener rizika

Drugo tromjesečje 2026.

Broj XIV, studeni 2026.

HANFA

SADRŽAJ

1. Uvodno 4
2. Rizici makroekonomskog i financijskog okružja 7
2.1. Makroekonomsko okružje 7
2.2. Financijsko okružje 10
3. Rizici sektora financijskih usluga 15
3.1. Kratkoročni rizici 15
3.2. Dugoročni rizici 18
Okvir 1. Umjetna inteligencija kao izvor sistemskih rizika 22
Popis kratica 35

Hrvatska agencija za nadzor financijskih usluga

Adresa: Franje Račkoga 6, 10000 Zagreb

Telefon centrale: +385 1 6173 200

Telefaks: +385 1 4811 406

WEB: **www.hanfa.hr**

ISSN: 2671-2067

Molimo korisnike ove publikacije da prilikom korištenja podataka obvezno navedu izvor.

1. UVODNO

Hrvatska agencija za nadzor financijskih usluga (dalje u tekstu: Hanfa) odgovorna je, uz Hrvatsku narodnu banku i Ministarstvo financija, za stabilnost financijskog sustava u Republici Hrvatskoj pa je promicanje i očuvanje financijske stabilnosti, u skladu sa Zakonom o Hrvatskoj agenciji za nadzor financijskih usluga, jedan od osnovnih ciljeva njezina rada. ***Stabilan financijski sustav*** podrazumijeva nesmetano funkcioniranje svih njegovih segmenata (financijskih institucija, tržišta, usluga i infrastrukture) u procesu alokacije resursa, procjene i upravljanja rizicima te izvršavanja plaćanja, kao i njegovu otpornost na iznenadne šokove.

Financijsku stabilnost mogu narušiti procesi koji nastaju i razvijaju se unutar samog sustava stvarajući ranjivosti koje se u slučaju javljanja određenih šokova mogu materijalizirati u vidu narušenih likvidnosnih i kapitalnih pozicija financijskih institucija onemogućavajući nesmetano funkcioniranje dijela ili cijelog financijskog sustava. Pritom šokovi mogu biti vanjski i poteći iz međunarodnog okruženja ili idiosinkratski – generirani domaćim makroekonomskim i financijskim kretanjima, ekonomskom politikom ili promjenama u institucionalnom okruženju. Stoga svaki rizik kojem je sustav izložen, a koji može imati negativne posljedice za funkcioniranje dijela ili cijelog financijskog sustava uzrokujući pritom i ozbiljan negativan utjecaj na realno gospodarstvo, predstavlja ***sistemski rizik***.

Na globalnoj je razini ostvaren velik napredak u dijelu razumijevanja, a time i identifikacije, procjene te praćenja sistemskih rizika financijskog sektora. No kako bi se identificirani rizici pravovremeno prevenirali odnosno kako bi se ublažio efekt njihove materijalizacije, potrebno je razviti i odgovarajući skup instrumenata i alata, odnosno politika usmjerenih na očuvanje stabilnosti sustava u cjelini, koje se zajednički nazivaju ***makrobonitetne politike***. Stoga su u Europskoj uniji (EU) na nacionalnoj i internacionalnoj razini nakon globalne financijske krize uspostavljena tijela s makrobonitetnim ovlastima i mandatima, a uz makrobonitetne alate razvijeni su i okviri za međunarodnu suradnju. Premda je u inicijalnoj fazi razvoja makrobonitetnih kapaciteta fokus primarno bio usmjeren na bankarski sektor, rastući udio i značaj nebankarskog dijela financijskog sustava stvara strukturne promjene i zahtijeva daljnji razvoj makrobonitetnog okvira i proširenje na sektor financijskih usluga kako bi se adekvatno adresirao sistemski rizik i spriječila regulatorna arbitraža. Usto, financijska se integracija kontinuirano produbljuje, što stvara potrebu za holističkim pristupom, koji sustav promatra kao nerazdvojivu cjelinu, čiji ključni dio čini praćenje i adresiranje ranjivosti u međusektorskom, ali i prekograničnom kontekstu.

Publikacija ***Makroprudencijalni skener rizika*** stoga pruža uvid u proces identifikacije, procjene i praćenja evolucije sistemskih rizika u sektoru financijskih usluga, koji je pod nadzorom Hanfe, kako bi se pravovremeno poduzele odgovarajuće mjere u cilju sprječavanja njihove materijalizacije i narušavanja stabilnosti financijskog sustava. Time se doprinosi boljem razumijevanju sistemskih rizika, posebno u segmentu identificiranja ranjivosti kao i kanala širenja rizika, potiče na planiranje aktivnosti i mjera koje pružaju odgovarajuću zaštitu od posljedica materijalizacije tih rizika i pridonosi većem povjerenju u financijski sustav te jačanju otpornosti sustava na šokove.

Slika 1. Matrica sistemskih rizika za prvu polovicu 2026. godine



Napomena: Ocjene sistemskih rizika procijenjene su uzimajući u obzir posljednje dostupne podatke u promatranoj kategoriji rizika. Za detaljno objašnjenje metodologije vidi Financijska stabilnost 1, Okvir 1
Izvor: Hanfa

Makroekonomski uvjeti blago su se pogoršali u prvoj polovici 2026. godine. Gospodarska aktivnost je pokazala znakove usporavanja uz istovremeno jačanje inflacijskih pritisaka kao posljedica realizacije geopolitičkih rizika. Unatoč rastućim neizvjesnostima, deficit i dug opće države ostali su stabilni, što je osiguralo relativnu stabilnost prinosa na domaće državne obveznice. Financijska tržišta su u prvoj polovici 2026. poslovala u okolnostima povišene volatilnosti i monetarne neizvjesnosti, no dionička vrednovanja nastavljaju obarati rekorde. Zbog visokih vrednovanja tehnoloških kompanija i snažnih očekivanja povezanih sa primjenom umjetne inteligencije, ciklički sistemski rizici ocijenjeni su visokima. Pritom umjetna inteligencija predstavlja izvor sistemskih rizika i izvan tržišnog kanala. Njena sve šira primjena u svakodnevnom poslovanju povećava ovisnost financijskih institucija ograničenom broju pružatelja AI usluga, a time i izloženost operativnim poremećajima i kibernetičkim prijetnjama. Takva koncentracija povećava međusobnu povezanost institucija i izloženost zajedničkim poremećajima, što otvara dodatan tehnološki kanal širenja sistemskog rizika. Pozitivna kretanja u domaćem sektoru financijskih usluga nastavljena su tijekom prve polovice 2026., a obilježili su ih rast vrednovanja i opsega trgovanja na domaćoj burzi te snažan priljev sredstava u investicijske i mirovinske fondove te leasing društva. Otpornost domaćeg sektora financijskih usluga dodatno je povećana uz rast diverzifikacije ulaganja i smanjenje ročnosti ulaganja u kombinaciji sa relativno visokim prinosima fondova i rastom kapitaliziranosti osiguranja i leasing društava. Unatoč pozitivnim lokalnim kretanjima, rastuće globalne napetosti blago su povisili sistemske rizike sektora, gdje kamatni i tržišni rizik ostali najizraženiji kanali potencijalnog prelijevanja sistemskih rizika.

2. RIZICI MAKROEKONOMSKOG I FINANCIJSKOG OKRUŽJA

2.1. Makroekonomsko okružje

Makroekonomski uvjeti blago su se pogoršali u prvoj polovici 2026. godine, gospodarskog rasta i ponovno jačanje inflacijskih pritisaka, ponajprije pod utjecajem geopolitičkih napetosti i rasta cijena energenata. Unatoč usporavanju, domaće gospodarstvo nastavilo je rasti brže od prosjeka EU-a, dok je tržište rada zadržalo povoljna kretanja, uz nisku nezaposlenost i snažan rast plaća. Inflacija se nakon proljetnog ubrzanja postupno smanjivala, no ostala je izložena vanjskim cjenovnim šokovima i domaćim troškovnim pritiscima. Fiskalni pokazatelji blago su se pogoršali, uz rast proračunskog deficita, dok je javni dug ostao na razmjerno niskoj razini u usporedbi s većinom država članica EU-a. Na tržištu nekretnina nastavljen je rast cijena unatoč smanjenju broja transakcija i naznakama usporavanja građevinske aktivnosti, zbog čega ranjivosti povezane s tim tržištem ostaju izražene.

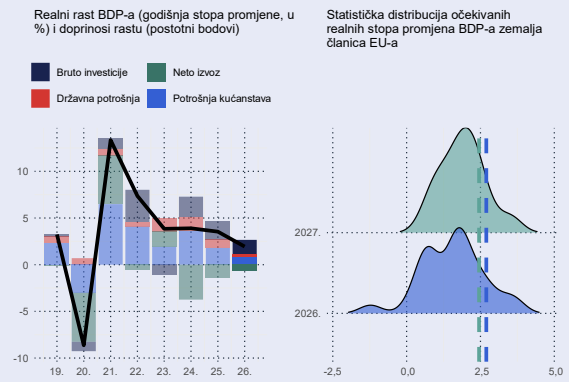
Gospodarski rast znatno je usporio u drugom tromjesečju 2026., prvenstveno zbog usporavanja potrošnje kućanstava i investicija u fiksni kapital (slika 2.1.). Realni BDP porastao je 1,7 % u drugom tromjesečju 2026. na godišnjoj razini, značajno manje nego u istom razdoblju prošle godine kada je porastao za 3,8%. To je ujedno i najniža stopa rasta od 2020., ali više od prosjeka EU od 1,2%. Rast potrošnje kućanstava usporio je s 2,8 % na kraju 2025. na 0,9 %, dok su investicije još izraženije usporile sa 7,0 % na 1,7 % u istom razdoblju. Usporavanje investicija povezano je prvenstveno sa slabijom građevinskom aktivnošću, usporavanjem prerađivačke industrije i pada stručnih, znanstvenih, tehničkih i administrativnih usluga. Na potrošnju kućanstva negativno je utjecalo ubrzanje inflacije povezano s rastom cijena energenata, dok usporavanje investicija ukazuje na završetak projekata financiranih iz fondova EU-a s približavanjem kraja aktualnog proračunskog razdoblja. Doprinos neto izvoza bio je u promatranom razdoblju negativan poglavito zbog rasta realnog uvoza roba (godišnji rast od 2,5%) i snažnog rasta realnog uvoza usluga (godišnji rast od 7,8 %), koji je djelomično ublažen rastom realnog robnog izvoza (godišnji rast od 5,2 %) zbog čega je došlo do poboljšanja omjera uvoza i izvoza roba. Preliminarni podatci o turističkoj sezoni u 2026.[1] ukazuju na izgledni pozitivan doprinos turizma neto izvozu u narednom tromjesečju.

Unatoč prisutnim rizicima, kratkoročni izgledi za rast domaćeg gospodarstva ostaju povoljniji u odnosu na ostatak EU. Europska komisija u svojoj **proljetnoj projekciji** predviđa usporavanje rasta domaćeg gospodarstva na 2,7 % u 2026. i 2,5 % u 2027. godini, primarno zbog rasta

[1] U srpnju su dolasci stranih turista rasli za 2,0% dok su noćenja rasla za 0,6%. U kolovozu su dolasci stranih turista rasli za 1,4 % dok su noćenja bila približno jednaka kao u kolovozu 2025.

cijene energenata u 2026. godini. Hrvatska bi se unatoč tome trebala zadržati među članicama EU-a s višim stopama gospodarskog rasta (slika 2.1.).

Slika 2.1. Rast domaćeg gospodarstva značajno usporio u drugom tromjesečju 2026. godine

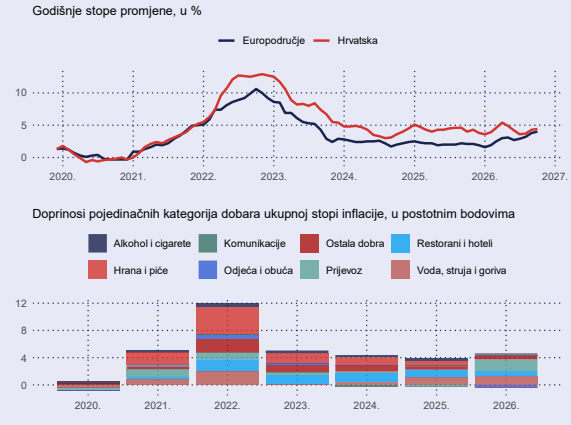


Napomena: Podatak za 2026. označuje stopu promjene BDP-a ostvarenog u prva dva tromjesečja 2026. u odnosu na isto razdoblje prethodne godine. Na desnom grafikonu prikazane su statističke distribucije očekivanih realnih stopa rasta BDP-a za 2026. i 2027. godinu. Vertikalne linije označuju očekivane realne stope rasta BDP-a za Hrvatsku za isto razdoblje.
Izvori: Eurostat, Europska komisija (DG-ECFIN)

Rizici za gospodarski rast u narednom razdoblju uglavnom proizlaze iz vanjskog okruženja. Geopolitičke napetosti i kretanje cijena energenata mogli bi imati izraženije makroekonomske učinke u slučaju iznenadnih promjena, uz istovremeno jačanje volatilnosti na financijskim tržištima. Rizike za domaće gospodarstvo dodatno naglašava usporavanje rasta glavnih trgovinskih partnera u EU, praćenog sa padom konkurentnosti izvoza i suženim fiskalnim prostorom. Ovi čimbenici i bez dodatnih geopolitičkih šokova srednjoročno stvaraju negativni pritisak na domaći gospodarski rast.

Inflatorni pritisci u Hrvatskoj ojačali su tijekom prve polovine 2026., primarno zbog realizacije geopolitičkih rizika i rasta cijena energenata. Prema harmoniziranom indeksu potrošačkih cijena inflacija je na kraju kolovoza iznosila 3,7 %, nakon što je u travnju dosegnula najvišu razinu od kraja 2023. godine (5,4 %). Ubrzanju rasta cijena najviše su pridonijele cijene energenata, koje su u kolovozu bile čak 16,9% više nego godinu ranije, te cijene usluga (rast za 5,6%). Istodobno su cijene hrane stagnirale, dok su cijene industrijskih proizvoda čak pale za 1,1 %.

Slika 2.2. Cijene energenata sve više doprinose inflaciji



Napomena: Stopa inflacije mjerena je harmoniziranim indeksom potrošačkih cijena.Ostala dobra uključuju kategorije: namještaj, edukacija, zdravlje te rekreacija i kultura.Podatci za 2026. odnose se na kolovoz 2026.
Izvor: Eurostat

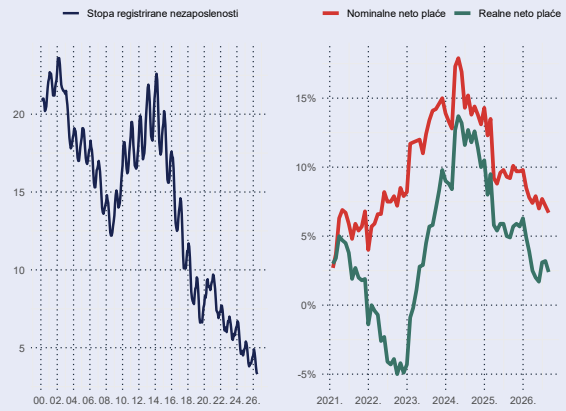
Rast cijena energenata posljedica je ponajprije geopolitičkih napetosti i poremećaja na globalnom tržištu energenata. Eskalacija sukoba Irana i SAD-a u ožujku dovela je do ograničenja prometa kroz Hormuški tjesnac, važnu pomorsku rutu za globalnu trgovinu naftom i plinom[2]. Uz to što je fizički poremetio opskrbne lance, taj je događaj dodatno povećao strah od dodatnih eskalacija i poremećaja u opskrbi, što samo po sebi može biti dovoljno da poveća cijene ključnih energenata (više o utjecaju geopolitičkog rizika na financijsku stabilnost u Okviru 1 u **Makroprudencijalnom skeneru rizika 12**). Iako je promet naknadno djelomično obnovljen, rizik od ponovne eskalacije drži cijene energenata na povišenim razinama.

[2] Kroz tjesnac je po **procjenama** prije početka sukoba prolazilo čak 25% svjetskog pomorskog transporta nafte i 20% svjetskog pomorskog transporta plina.

Inflaciju i dalje podupiru pritisci na domaćem tržištu rada, iako temeljna inflacija postupno slabi. Napregnuto tržište rada, obilježeno niskom nezaposlenošću i snažnim rastom plaća, održava pritiske na cijene usluga. Stopa nezaposlenosti na kraju kolovoza iznosila je povijesno niskih 3,4 %, dok su neto plaće u srpnju na godišnjoj razini porasle za 7,2 % nominalno i 3,2 % realno, nešto sporije u odnosu na prethodnu godinu (slika 2.3.). Unatoč tim pritiscima, rast cijena usluga usporio je tijekom posljednjih mjeseci, a temeljna inflacija u kolovozu se spustila na 2,7 %, najnižu razinu od početka 2022. godine. Ograničena ponuda radne snage, povezana s nepovoljnim demografskim kretanjima i strukturnim nesrazmjerom ponude i potražnje za radom, pritom otežava popunjavanje radnih mjesta, osobito u radno intenzivnim djelatnostima poput turizma, ugostiteljstva i građevinarstva. Bez odgovarajućeg rasta produktivnosti, nastavak snažnog rasta plaća mogao bi dodatno opteretiti troškovnu konkurentnost poduzeća, osobito u uvjetima usporavanja domaćeg i europskog gospodarstva.

Izgledi za inflaciju i dalje su izrazito osjetljivi na kretanje cijena energenata i domaćih troškovnih pritisaka. Zbog pojačanih pritisaka na cijene energije, Europska komisija predviđa ubrzavanje inflacije na 4,6 % u 2026. godini, dok se u 2027. očekuje smirivanje na 2,7 %. Takve projekcije izložene su negativnim rizicima, pri čemu bi novi geopolitički šokovi mogli dodatno pogoršati makroekonomske izglede u nadolazećem razdoblju.

Slika 2.3.Unatoč usporavanja gospodarstva tržište rada i dalje je napregnuto
Stopa nezaposlenosti i mjesečne neto plaće, u %



Izvor: DZS

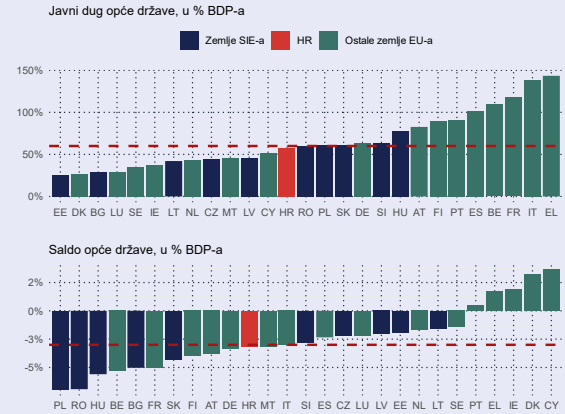
Fiskalni pokazatelji blago su pogoršani u prvom tromjesečju 2026. nakon duljeg perioda stabilnosti, no relativna razina javnog duga i dalje je povoljna u usporedbi s većinom država članica EU-a. Javni je dug na kraju prvog tromjesečja 2026. iznosio 58,4 % BDP-a, što je 0,1 p.b. više nego godinu ranije. Hrvatska i dalje bilježi jedan od nižih omjera javnog duga i BDP-a među državama članicama EU-a (slika 2.4.), znatno ispod prosjeka europodručja (89,4 %) i EU-a (82,9 %). Valutna i ročna struktura duga je ostala povoljna[3], dok se udio inozemnog duga neznatno povećao za 2,5 postotna boda, u odnosu na isto razdoblje prošle godine, na 70,5 %.

Istodobno se fiskalni saldo pogoršao te je deficit na kraju ožujka iznosio 3,2 %, 0,4 p.b. više nego godinu ranije. Rizik daljnjeg pogoršanja fiskalnih pokazatelja proizlazi iz naglašenog oslanjanja proračunskih prihoda na osobnu potrošnju građana te mogući rast troška subvencijskih mjera kojima se ublažava efekt rasta cijena energenata. Dodatni rizik je i potencijalni

[3] Gotovo sav dug je denominiran u eurima dok je udio dugoročnog duga u ukupnom 90,2 %

rast troška zaduživanja kao posljedica rasta prinosa na nerizične obveznice. Jačanje inflacijskih kretanja kratkoročno povoljno djeluje na porezne prihode povezane s nominalnim rastom potrošnje i dohotka te djelomično ublažava nepovoljne pritiske na javne rashode.

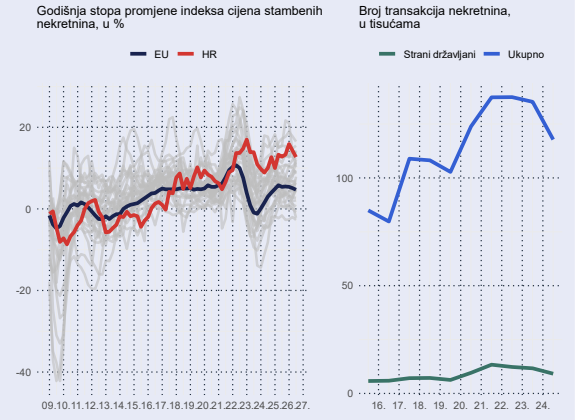
Slika 2.4. Fiskalni pokazatelji zamjetno pogoršani



Napomena: Podaci o javnom dugu i saldu opće države odnose se na 31.03.2026. godine. Istaknute razine označuju razine javnog duga i proračunskog salda definirane kriterijima konvergencije na temelju Ugovora iz Maastrichta.
Izvor: Eurostat

Rizici za domaće makroekonomsko okružje proizlaze i iz nastavka snažnog rasta cijena stambenih nekretnina, koji je nastavljen i u drugom tromjesečju 2026. godine (slika 2.5.). **Mjere HNB-a** kojima su pooštreni kriteriji kreditiranja potrošača nisu rezultirale zamjetnijim smanjenjem potražnje za nekretninama, ponajprije zbog kratkog razdoblja njihove primjene, ali i relativno ograničenog dosega, s obzirom na to da se znatan dio kupoprodaja financira izvan kreditnog kanala. Ipak, broj realiziranih transakcija zabilježio je značajan pad od 13,2 % u 2025., što može signalizirati moguću promjenu dinamike na tom tržištu. Usporavanje rasta građevinske aktivnosti te zamjetan pad novoizdanih građevinskih dozvola za nestambene nekretnine[4] također signaliziraju potencijalno ublažavanje tržišta nekretnina, iako cijene ne pokazuju znakove usporavanja.

Slika 2.5. Cijene nekretina i dalje rastu, ali je broj transakcija u padu



Napomena: Prikazani podaci ne sadrži podatke o ukupnoj kupoprodaji nekretnina, već isključivo o kupoprodaji za koje je Porezna uprava provela postupak utvrđivanja porezne osnovice.
Izvori: Eurostat i Porezna uprava

2.2. Financijsko okružje

Financijsko okružje u prvoj polovici 2026. obilježili su brz tržišni oporavak nakon početnog šoka izazvanog geopolitičkim napetostima te nastavak rasta vrednovanja na vodećim svjetskim, ali i domaćem tržištu kapitala. Unatoč stabilizaciji tržišta, visoka vrednovanja, osobito na američkom tržištu i u tehnološkom sektoru, povećavaju osjetljivost na promjene investicijskog sentimenta i rast troškova financiranja. Istodobno su dugoročni prinosi na državne obveznice porasli pod utjecajem globalnih čimbenika, bez zamjetnijeg pogoršanja percepcije kreditnog rizika Hrvatske. Na domaćem tržištu kapitala nastavljen je rast cijena i prometa, no uz visoku koncentraciju trgovanja i ograničenu dubinu tržišta, što povećava osjetljivost na nepovoljna kretanja cijena vodećih izdanja. Povišena vrednovanja na međunarodnim tržištima, uz strukturne ranjivosti povezane s primjenom

[4] Broj izdanih građevinskih dozvola u drugom kvartalu 2026 za nestambene nekretnine pao je za 16,3 % u odnosu na isto razdoblje prošle godine sa 349 na 292.

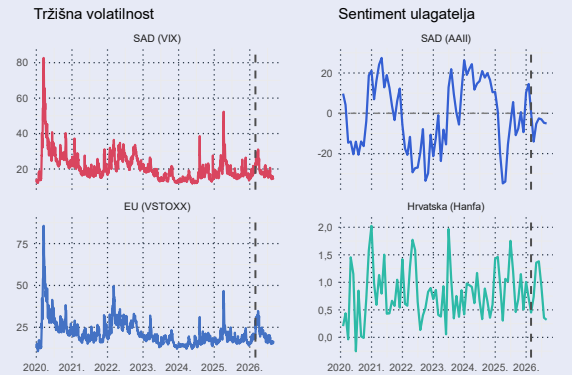
umjetne inteligencije, stoga zadržavaju cikličke sistemske rizike na visokoj razini.

Financijska tržišta brzo su se oporavila od početnog šoka izazvanog geopolitičkim napetostima i rastom cijena energenata, no visoka vrednovanja dionica i dalje ukazuju na visoke cikličke sistemske rizike.

Početkom ožujka eskalirao je sukob na Bliskom istoku, koji je rezultirao poremećajem prometa kroz Hormuški tjesnac i koji se nije normalizirao u nadolazećim mjesecima. Posljedični rast cijena energenata i zabrinutost zbog ponovnog jačanja inflacije kratkotrajno su povećali kolebljivost tržišta i oslabili sentiment ulagatelja (slika 2.6.). Do kraja ljeta tržišta su se stabilizirala, uz potpuni oporavak tržišnih cijena. Ipak, povijesno visoka vrednovanja, koja se oslanjaju na dugoročne koristi od tehnološkog razvoja u domeni umjetne inteligencije ostavljaju tržišta ranjivima na naglo pogoršanje investicijskog sentimenta, koji bi se izgledno odrazio i na poslovanje domaćeg sektora financijskih usluga (više u **Okviru 1. Umjetna inteligencija kao izvor sistemskih rizika**).

Slika 2.6. Pojačana tržišna volatilnost uz sve opreznji sentiment ulagatelja

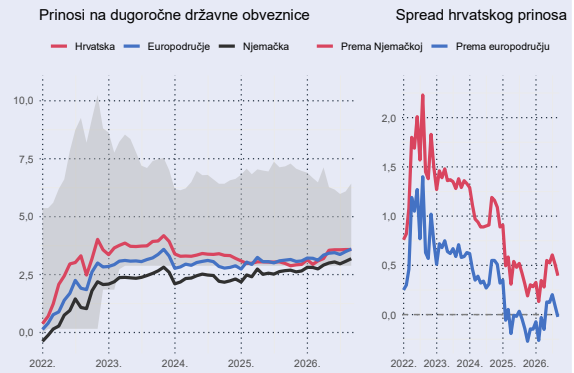
Indeksi volatilnosti i pokazatelji sentimenta ulagatelja



Napomena: Isprekidana okomita linija označava početak američko-izraelskih napada na Iran 28. veljače 2026. Američki pokazatelj sentimenta izračunat je kao razlika udjela optimističnih i pesimističnih ulagatelja u AAII anketi te je izražen u postotnim bodovima. Pokazatelji sentimenta temelje se na različitim metodologijama i njihove se razine ne uspoređuju izravno.
Izvori: AAII, Hanfa, St. Louis FED, STOXX

Slika 2.7. Rast referentnih prinosa povećava troškove financiranja unatoč povoljnijoj relativnoj percepciji Hrvatske

Prinosi i spreadovi na dugoročne državne obveznice, u postotnim bodovima



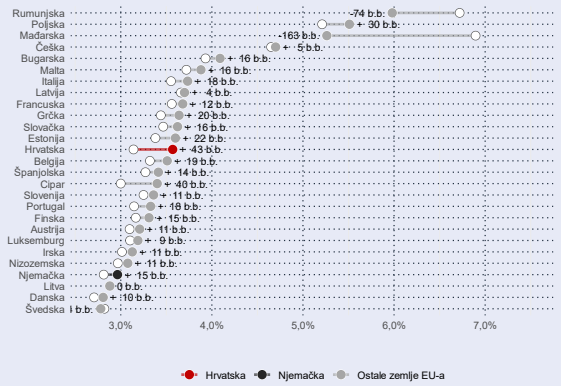
Napomena: Osjenčano područje na lijevom panelu označava puni raspon prinosa Bugarske, Češke, Estonije, Mađarske, Latvije, Litve, Poljske, Rumunjske, Slovenije i Slovačke. Spreadovi su izračunati kao razlika hrvatskog prinosa i prinosa Njemačke odnosno europodručja.
Izvor: Eurostat

Prinosi na dugoročne državne obveznice porasli su na međunarodnim tržištima tijekom drugog tromjesečja 2026., dok je premija rizika Hrvatske ostala razmjerno stabilna te ne upućuje na pogoršanje percepcije domaćeg državnog duga. Rast prinosa na državne obveznice tijekom 2026. odražava šira kretanja na međunarodnim tržištima, uključujući povećane fiskalne potrebe, veće troškove zaduživanja i rast terminskih premija. Rastu dugoročnih prinosa pridonijelo je i pooštravanje monetarne politike u europodručju. Nakon rasta cijena energije i kratkoročnih inflacijskih očekivanja tržišta su tijekom proljeća revidirala očekivanu putanju ključnih kamatnih stopa naviše, Europska središnja banka u lipnju je povisila ključne kamatne stope za 25 baznih bodova. Viša očekivana razina kratkoročnih kamatnih stopa prenijela se i na dulji kraj krivulje prinosa, dok je prestanak reinvestiranja glavnica dospjelih vrijednosnih papira kupljenih u sklopu programa kupnje vrijednosnih papira (APP) i hitnog programa kupnje zbog pandemije (PEPP)

ograničio potražnju središnjih banaka europodručja za obveznicama[5].

Slika 2.8. Dugoročni državni prinosi porasli u većini zemalja EU-a u prvoj polovici 2026. godine

Prosječni dugoročni državni prinosi prema maastrichtskoj definiciji, u %

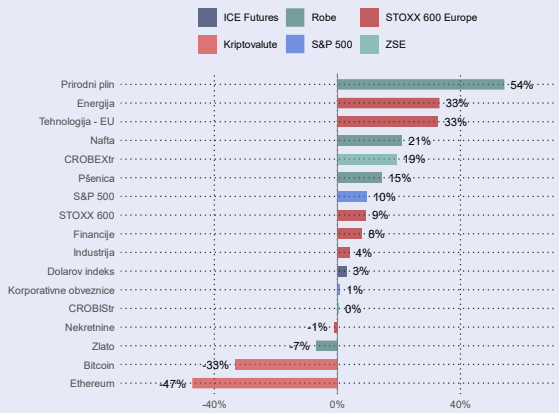


Napomena: Prazne točke prikazuju prosječne prinose u prosincu 2025., a pune točke prosječne prinose u lipnju 2026. Brojčane oznake prikazuju promjenu u baznim bodovima.
Izvor: Eurostat

Dodatni pritisci pojavili su se u travnju, u uvjetima pojačanih geopolitičkih i inflacijskih neizvjesnosti. Prinos na desetogodišnju njemačku obveznicu porastao je s 2,8 % krajem 2025. na 3,2 % krajem kolovoza 2026., dok je prinos zemalja europodručja porastao s 3,2 % na 3,6 %. Istovremeno je prinos na dugoročne obveznice RH porastao s 3,1 % na 3,6 %, zadržavajući stabilan raspon od 40 b.b. u odnosu na njemačke obveznice (slika 2.7.). Unatoč tom povećanju, relativno stabilni fiskalni pokazatelji i povećanje dugoročnog kreditnog rejtinga Hrvatske agencije S&P u ožujku 2026. upućuju na to da rast prinosa nije bio praćen pogoršanjem kreditne percepcije Hrvatske. Iako rast troška zaduživanja nije potaknut domaćim, nego globalnim kretanjima, njegov izgledan nastavak dodatno će u nadolazećem razdoblju pritisnuti postojeća vrednovanja, a potencijalno naglasiti i kreditni rizik u korporativnom segmentu sa nepovoljnim implikacijama na profitabilnost sektora financijskih usluga.

Slika 2.9. Kretanja pojedinih klasa financijske imovine u prvoj polovici 2026. godine

Promjena vrijednosti indeksa od kraja 2025. do kraja lipnja 2026. godine, u %



Izvori: YAHOO Finance, ZSE, St. Louis FED, Investing.com, ESB

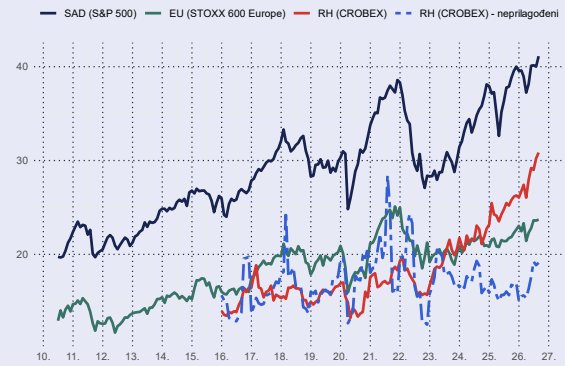
Brz oporavak cijena nakon proljetnog šoka povećao je raskorak između povoljnih tržišnih kretanja i dalje povišenih makrofinancijskih rizika. U prvoj polovici 2026. rast vrednovanja zabilježile su gotovo sve klase imovine izuzev zlata, kriptovaluta i obveznica. Najizraženiji rast vrednovanja zabilježili su energenti te tehnološke i energetske kompanije pod utjecajem snažnog rasta prihoda. Američki i europski burzovni indeksi S&P 500 i STOXX 600 porasli su za otprilike 10 %, a snažnu izvedbu (+19,2 %) ponovno je imao domaći dionički indeks CROBEXtr (slika 2.9.). Pritom je neto dobit pet najtrgovanijih dionica na kraju lipnja 2026. porasla za 15,7 % na godišnjoj razini[6]. Povoljni rezultati vodećih izdanja tako su pratili snažnu tržišnu izvedbu, premda je rast cijena odražavao i očekivanja budućih

[5] Reinvestiranje u sklopu APP-a obustavljeno je od srpnja 2023., a u sklopu PEPP-a krajem 2024. Budući da se dospjele obveznice više ne zamjenjuju novim kupnjama, portfelji Eurosustava nastavili su se smanjivati i tijekom 2026. Dodatno vidjeti na **Asset purchase programmes** i **Pandemic emergency purchase programme**.

[6] Pet dionica s najvećim kumulativnim redovnim prometom u razdoblju od 1. srpnja 2025. do 30. lipnja 2026. činili su KONČAR d.d. (KOEI), Adris grupa d.d., povlaštena dionica (ADRS2), Dalekovod d.d. (DLKV), KONČAR – Distributivni i specijalni transformatori d.d. (KODT) i Hrvatski Telekom d.d. (HT).

poslovnih rezultata te viša tržišna vrednovanja.

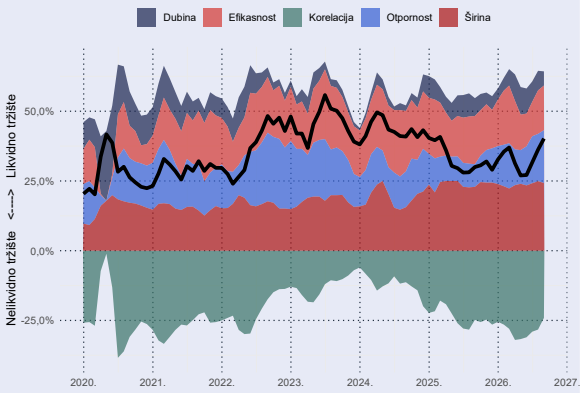
Slika 2.10. Visoka dionička vrednovanja povećavaju osjetljivost tržišta na korekciju
Ciklički prilagođeni omjer cijena i zarada na američkom, europskom i domaćem dioničkom tržištu



Napomena: Ciklički prilagođeni omjer cijene i zarada prikazuje koliko je puta vrijednost dionice viša od prosječne desetogodišnje zarade po dionici. Veća vrijednost označuje relativno više vrednovanje u odnosu na dugoročne zarade. Iscrtkana plava linija prikazuje neprilagođeni omjer cijena i zarada koji uzima u obzir trenutačne cijene i zarade poduzeća.
Izvori: Bloomberg, Eurostat, Robert J. Shiller, Hanfa

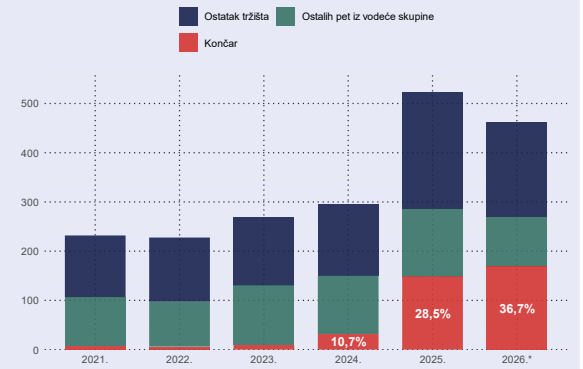
Vrednovanja na vodećim globalnim tržištima su zadržana na vrlo visokim razinama u povijesnom kontekstu i nalaze se na razinama posljednji puta viđenima tijekom 2001. godine netom prije Dot-com krize (vidjeti Sliku 4. u **Okvir 1. Umjetna inteligencija kao izvor sistemskih rizika**). Ciklički prilagođeni omjer cijene i zarada (CAPE) porastao je u prvih osam mjeseci 2026. s 39,6 na 41,1 u SAD-u te s 26,0 na 30,8 u Hrvatskoj, dok je u Europi ostao razmjerno stabilan na 23,7 (slika 2.10.). Povišena vrednovanja ne znače nužno skoru korekciju, ali povećavaju osjetljivost tržišta na slabiji rast korporativne dobiti ili pak rast kamatnih stopa. Rizik je osobito izražen na američkom tržištu, gdje su vrednovanja povijesno visoka i koncentrirana u tehnološkom sektoru (više u **Okviru 1. Umjetna inteligencija kao izvor sistemskih rizika**). Iako su domaća vrednovanja relativno niža i prate snažan rast dobiti vodećih kompanija, ona su ranjiva na nepovoljna globalna kretanja, a s obzirom na povišenu koncentraciju domaćeg tržišta i na poslovanje nekolicine vodećih izdavatelja na domaćem tržištu. Slabiji poslovni rezultati tih kompanija u okruženju rastućih troškova financiranja zato bi mogli istodobno pritisnuti vrednovanja, ali i tržišnu likvidnost uz nepovoljne implikacije na profitabilnost institucionalnih ulagatelja.

Slika 2.11. Likvidnost domaćeg dioničkog tržišta ostala je na niskoj razini
Tržišni indeks likvidnosti dionica (TILDA), u %



Napomena: Vrijednost TILDA indeksa od 100 % označava potpuno likvidno tržište, dok vrijednost od 0 % označava potpuno nelikvidno tržište.
Izvor: Hanfa

Slika 2.12. Rast prometa dionicama sve se više koncentrira na dionicu Končara
Struktura redovnog prometa dionicama na Zagrebačkoj burzi, u mil. EUR



Napomena: Vodeću skupinu čini šest dionica s najvećim kumulativnim redovnim prometom od 1. siječnja 2021. do 30. rujna 2026. Končar je prikazan zasebno, dok skupina ostalih pet iz vodeće skupine obuhvaća preostala izdanja iz tako definirane skupine. Oznake prikazuju udio Končara u ukupnom redovnom prometu dionicama. Podaci za 2026. odnose se na prvih devet mjeseci.
Izvori: Hanfa, ZSE

Pokazatelji likvidnosti ne upućuju na oporavak tržišne aktivnosti, uz i dalje visoku koncentraciju trgovanja. Indeks tržišne likvidnosti do kolovoza se oporavio nakon privremenog pogoršanja početkom drugog tromjesečja (slika 2.11.). Oporavku su najviše pridonijele komponente otpornosti i širine trgovanja, dok je dubina tržišta ostala relativno potisnuta. Kretanje pojedinih sastavnica indeksa likvidnosti upućuje na to da rast ukupne tržišne aktivnosti nije značajno

poboljšao likvidnost prosječne dionice. Slabija dubina ograničava mogućnost brže prodaje većih pozicija bez pritiska na cijene, pa rast ukupnog prometa ne znači nužno i bolju likvidnost pojedinačnih dionica na tržištu.

Redovni promet dionicama porastao je s 232 mil. EUR u 2021. na 522 mil. EUR u 2025., a u prvih devet mjeseci 2026. dosegnuo je 461 mil. EUR. Pritom se udio najlikvidnije dionice na tržištu u ukupnom prometu povećao s približno 3 % u 2021. na 36,7 % u prvih devet mjeseci 2026., dok se udio pet sljedećih vodećih dionica smanjio s 42,8 % na 21,8 %, a udio ostatka tržišta s 54,2 % na 41,5 % (slika 2.12.). Istovremeno je udio pet najtrgovanijih dionica u ukupnom prometu porastao s 51,2 % u ožujku na 63,3 % u lipnju te se u srpnju i kolovozu približio 70 %. Udio dionica kojima se trgovalo manje od deset dana u mjesecu povećao se s 35 % u ožujku na 54 % u kolovozu, premda se u lipnju privremeno vratio na početnu razinu. Međutim, ukupan broj dionica kojima se trgovalo pao je sa 62 u ožujku na 55 u lipnju, čime je nastavljen dugoročniji pad broja aktivno trgovanih izdanja. Visoka koncentracija trgovanja ograničava širinu domaćeg tržišta i povećava njegovu osjetljivost na nepovoljna kretanja cijena najtrgovanijih dionica.

3. RIZICI SEKTORA FINANCIJSKIH USLUGA

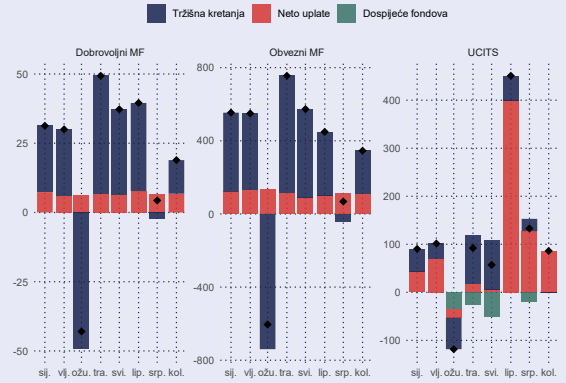
3.1. Kratkoročni rizici

Domaći sektor financijskih usluga nastavio je rasti u prvoj polovici 2026., uz snažan rast imovine mirovinskih i investicijskih fondova te povećanje opsega poslovanja osiguratelja i leasing društava. Rast imovine fondova odražavao je pozitivna tržišna kretanja i priljev novih sredstava, pri čemu su se osobito istaknuli novčani fondovi i fondovi s dospijećem. Unatoč visokom udjelu likvidne imovine, koncentracija ulagatelja u novčanim fondovima i njihova ovisnost o bankovnim distribucijskim kanalima zadržavaju važnost rizika naglih odljeva sredstava. Rast troškova šteta u osiguranjeljnom sektoru i rast kamatnih troškova u sektoru leasing društava nastavljaju pritiskati pokazatelje profitabilnosti. Ukupna otpornost sektora ostala je relativno visoka zahvaljujući pozitivnim domaćim kretanjima, no rastuće ranjivosti u globalnom okruženju naglašavaju sistemske rizike domaćeg sektora financijskih usluga u prvoj polovici 2026. godine.

Neto imovina mirovinskih i investicijskih fondova nastavila je snažno rasti u drugom tromjesečju 2026., potaknuta pozitivnim tržišnim kretanjima te priljevom novih sredstava (slika 3.1.). Do kraja kolovoza 2026. godine neto imovina mirovinskih fondova dosegnula je 31,0 mlrd. EUR što je za 10,2 % više u odnosu na kraj 2025. godine. Rast je bio podjednako zastupljen i u segmentu obveznih i u segmentu dobrovoljnih mirovinskih fondova[7] te je primarno odražavao pozitivna tržišna kretanja i nove uplate. Neto uplate u obvezne mirovinske fondove u prvih osam mjeseci 2026. iznosile su 871,5 mil. EUR, a u dobrovoljne 54,1 mil. EUR. Istovremeno je zabilježeno i povećanje broja članova obveznih mirovinskih fondova za 1,0 %, dok je kod dobrovoljnih mirovinskih fondova zabilježen rast od 4,1 %.[8]

Slika 3.1. Neto imovina domaće fondovske industrije pod utjecajem tržišnih kretanja i neto uplata

Mjesečna promjena neto imovine mirovinskih i investicijskih fondova, u mil. EUR



Napomena: Točke prikazuju iznos mjesečne promjene neto imovine.
Izvor: Hanfa

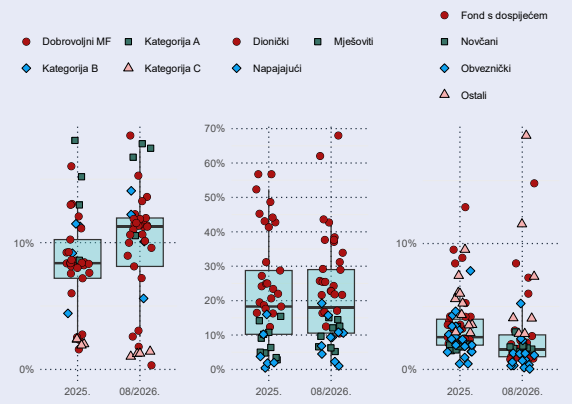
Neto imovina UCITS fondova krajem kolovoza 2026. dosegnula je 4,9 mlrd. EUR, što je 28,0 % više nego godinu prije. Time je nastavljen snažan rast sektora, a najveći doprinos imali su priljevi sredstava u novčane fondove te u fondove s dospijećem, koji su u prvih 8 mjeseci 2026. godine ostvarili 35,8 % ukupnih neto

[7] U promatranom razdoblju imovina obveznih mirovinskih fondova porasla je za 10,2 %, dosegnuvši 29,1 mlrd. EUR, dok je imovina dobrovoljnih mirovinskih fondova povećana za 10,1 %, na ukupno 1,8 mlrd. EUR.

[8] U prvih osam mjeseci broj članova obveznih mirovinskih fondova porastao je za 23,4 tisuće te je krajem kolovoza 2026. iznosio 2,4 milijuna, dok je broj članova dobrovoljnih mirovinskih fondova porastao za 20,2 tisuće i dosegnuo 515,4 tisuće članova.

priljeva u UCITS fondove, čime je njihova imovina dosegnula 0,8 mlrd. EUR (15,4 % neto imovine sektora) te se gotovo izjednačila s razinom imovine obveznićkih fondova[9].

Slika 3.2. Godišnji prinosi Mirovinskih i UCITS fondova
godišnji prinosi, u %



Napomena: Prinosi prikazani na zadnji datum izračunati su u odnosu na cijene udjela na kraju istog mjeseca prethodne godine
Izvor: Hanfa

Izraženi priljevi sredstava u fondove s dospijećem pridonijeli su povećanju ulaganja UCITS fondova u obveznice koje su krajem kolovoza činile 1,5 mlrd. EUR odnosno 30,8 % ukupnih ulaganja UCITS fondova[10]. Udio likvidne imovine zadržao se na visokih 41,6 %, što odražava značajnu zastupljenost novčanih fondova, koji su na kraju kolovoza činili 35,1 % ukupne imovine UCITS fondova i u kojima se nalazi čak 84,5 % ukupne visokolikvidne imovine[11] UCITS fondova. Premda je likvidnost novčanih fondova formalno gotovo potpuna, rizik naglih i snažnih odljeva sredstava nije u potpunosti eliminiran, budući da mali ulagatelji i dalje čine najveći dio ulagateljske baze, s udjelom od 73,4 % na kraju lipnja i da se plasmani i distribucije udjela dominantno odvijaju kroz bankovni kanal (više u okviru 1. Novčani fondovi – bolja štednja ili drugačija investicija? u publikaciji **Makroprudencijalni skener rizika br. 13.**). Stoga primjerena razina likvidnosti ostaje važan faktor otpornosti sektora, osobito u uvjetima pojačane geopolitičke neizvjesnosti i rastućih cikličkih rizika na financijskim tržištima (više u poglavlju **2.1. Makroekonomsko okružje** i **2.2. Financijsko okružje**).

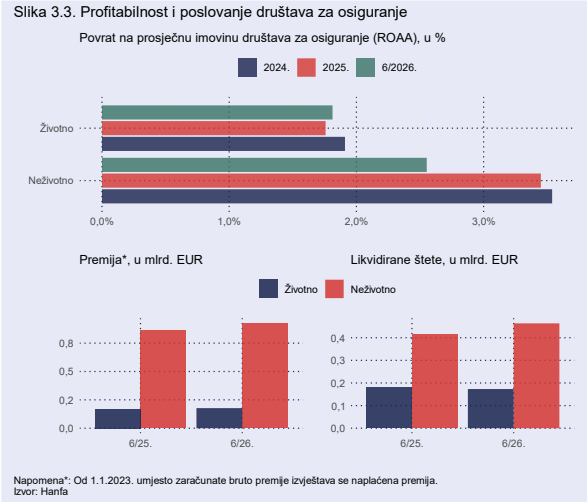
Oporavak tržišnih kretanja nakon početnih nestabilnosti početkom 2026. pridonio je rastu prinosa mirovinskih i investicijskih fondova. Nominalni godišnji prinosi mirovinskih fondova u potpunosti su se oporavili od kratkotrajnih tržišnih oscilacija na početku godine te su krajem kolovoza iznosili 19,1 % za kategoriju A, 10,4 % za kategoriju B te 1,2 % za kategoriju C (slika 3.2.). Dionički fondovi također su zabilježili vrlo dobre nominalne prinose u prvih osam mjeseci (24,8 %), a slijedili su mješoviti fondovi (8,5 %). Prinosi konzervativnijih fondova poput fondova s dospijećem (2,3 %), novčanih fondova (1,6 %) i obveznićkih fondova (0,7 %) ostali su relativno potisnuti, zbog rasta prinosa na državne obveznice (više u poglavlju **2.2. Financijsko okružje**) te nisu u potpunosti kompenzirali učinak inflacije, zabilježivši negativne realne prinose. Također se pod utjecajem povišenih kamatnih rizika nastavio trend pada prinosa obveznićkih fondova, koji su krajem kolovoza bili najniži među svim kategorijama investicijskih fondova. (slika 3.3.). Iako rast kamatnih stopa kratkoročno nepovoljno djeluje na profitabilnost fondova,

[9] Udio imovine obveznićkih fondova u ukupnoj imovini UCITS fondova na dan 31.8.2026. iznosio je 0,8 mlrd EUR odnosno 16,2 % neto imovine sektora.

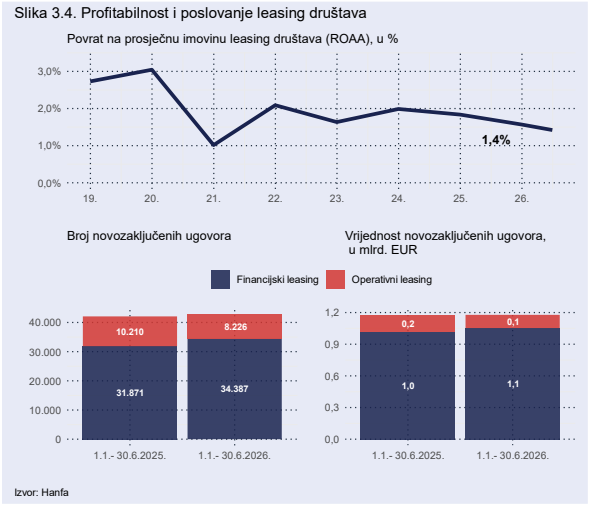
[10] Udio obveznica u ukupnim ulaganjima povećao se sa 1,4 mlrd. EUR na 1,5 mlrd. EUR odnosno za 6,2 % na godišnjoj razini.

[11] Visokolikvidna imovina odnosi se na novac, depozite i instrumente tržišta novca, poput trezorskih zapisa i drugih kratkoročnih dužničkih vrijednosnih papira visoke kreditne kvalitete.

srednjoročno više kamatne stope pozitivno djeluju na poslovanje obveznickih fondova jer ublažavaju rizik reinvestiranja.



Ukupna naplaćena premija osiguranja u prvoj polovici 2026. iznosila je 1,1 mlrd. EUR, što je za 6,7 % više nego u istom razdoblju prethodne godine. Rastu je ponovno najviše pridonijela premija neživotnih osiguranja koja je porasla za 7,3 % (uz rast broja polica od 8,0 %), a porasla je i naplaćena premija životnih osiguranja za 3,6 % (uz rast broja polica od 1,5 %). Istodobno su likvidirane štete porasle za 7,2 % na godišnjoj razini. Rast je ponajprije odražavao povećanje iznosa likvidiranih šteta u neživotnom osiguranju za 11,9 %, dok su likvidirane štete u životnom osiguranju usporile za 3,6 %. Unatoč povećanju ukupnog iznosa likvidiranih šteta u neživotnom osiguranju, njihov se broj smanjio za 7,9 %. Rast obveza za nastale štete upućuje na nastavak inflatornih pritisaka na troškove naknade šteta, u vidu rasta cijena rada i rezervnih dijelova. Trajniji rast troškova šteta, ako nije pravodobno praćen prilagodbom premija, može smanjiti profitabilnost osiguratelja i otežati održavanje adekvatnosti premija u odnosu na preuzete rizike. Povećanje troškova šteta opteretilo je financijski rezultat osiguratelja te, dovelo do pada profitabilnosti neživotnog osiguranja čiji je povrat na prosječnu imovinu krajem lipnja 2026. iznosio svega 2,6 %. Istodobno je profitabilnost prosječne imovine životnih osiguranja ostala relativno stabilna na razini od 1,8 % (slika 3.3).



Vrijednost i broj novih ugovora o financijskom leasingu nastavila je rasti i u prvoj polovici 2026. (slika 3.4.), čime je ukupna imovina sektora porasla za 10 % na 5,0 mlrd. EUR, dosegnuvši najvišu razinu od početka praćenja podataka, odnosno od 2005. godine. Iako je i dalje riječ o relativno snažnom rastu opsega poslovanja leasing društava, dinamika rasta pokazuje znakove usporavanja (godišnji rast od 3,7% u odnosu na 6,4 % u prvoj polovici 2025. godine)[12], što pak odražava rastuće makroekonomske rizike i blago usporavanje rasta gospodarske aktivnosti. Ugovori o financijskom leasingu su na kraju lipnja 2026. činili

[12] Rast broja novozaključenih ugovora o financijskom leasingu iznosio je 7,9 %, dok je broj novozaključenih ugovora o operativnom leasingu pao za -19,4% na godišnjoj razini.

88,5 % vrijednosti svih aktivnih ugovora, koja je na godišnjoj razini porasla za 7,9 %.

Unatoč nominalnom rastu operativne dobiti u prvom polugodištu 2026., profitabilnost leasing društava ostala je izložena pritiscima rasta rashoda za amortizaciju imovine dane u operativni leasing te rasta kamatnih rashoda prema domaćim i inozemnim financijskim institucijama.

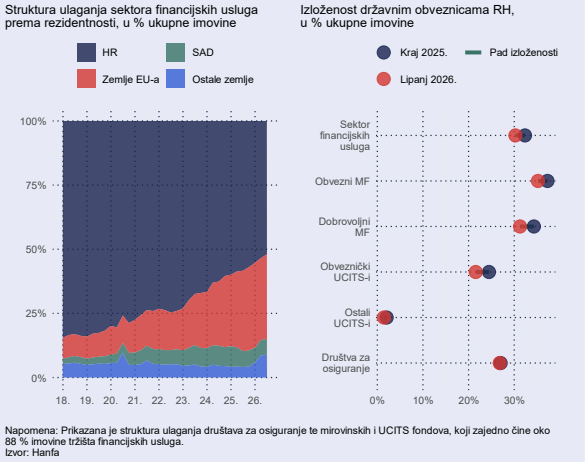
3.2. Dugoročni rizici

Dugoročne ranjivosti sektora financijskih usluga tijekom drugog tromjesečja 2026. uglavnom su ostale stabilne, uz nastavak geografske i imovinske diversifikacije ulaganja. Smanjenje izloženosti domaćem državnom dugu i povećanje ulaganja u inozemne vrijednosne papire pridonijeli su ravnomjernijoj raspodjeli portfeljnih rizika, ali i povećali osjetljivost sektora na globalna tržišna kretanja. Unatoč skraćivanju ročnosti obvezničkih ulaganja, kamatni rizik ostao je jedan od važnijih izvora ranjivosti zbog visoke zastupljenosti obveznica u portfeljima i ročne neusklađenosti imovine i obveza osiguratelja. Kreditni i valutni rizici zadržali su se na niskim razinama, dok je kapitaliziranost sektora ostala visoka i stabilna. Klimatski rizici i dalje proizlaze ponajprije iz izloženosti fizičkim rizicima, osobito u uvjetima ograničene osigurateljne zaštite od elementarnih nepogoda.

Tijekom drugog tromjesečja 2026. nastavljen je trend geografske i imovinske diversifikacije ulaganja sektora financijskih usluga. Udio domaćih državnih obveznica u ukupnim ulaganjima smanjen je na 30,3 % krajem drugog tromjesečja 2026. (slika 3.5.), pri čemu je pad izloženosti domaćem državnom dugu zabilježen kod svih skupina institucionalnih investitora, a izloženost je i dalje najizraženija kod obveznih mirovinskih fondova (35,2 %). Istodobno su porasle prekogranične izloženosti prema izdavateljima iz EU-a, čiji je udio povećan na 13, 9 %, dok je ukupna zastupljenost državnih obveznica smanjena za 1,8 p.b. na 49,3 %. Udio dioničkih ulaganja povećan je za 1,2 p.b. (na 24,2 %), koji je dodatno potpomognut snažnim rastom vrednovanja na domaćim i međunarodnim dioničkim tržištima.

Nastavak diversifikacije pridonosi smanjenju koncentracije ulaganja i može ojačati otpornost sektora na idiosinkratske rizike u pojedinim segmentima tržišta. Međutim, veća izloženost inozemnim tržištima povećava osjetljivost sektora na promjene globalnog sentimenta i iznenadne korekcije cijena, osobito u okružju i dalje potisnute premije za rizik te povišenih razina geopolitičke i makroekonomske neizvjesnosti (više u poglavljima **2.1. Makroekonomsko okružje** i **2.2. Financijsko okružje**).

Slika 3.5. Nastavljen trend smanjenja koncentracije ulaganja sektora financijskih usluga

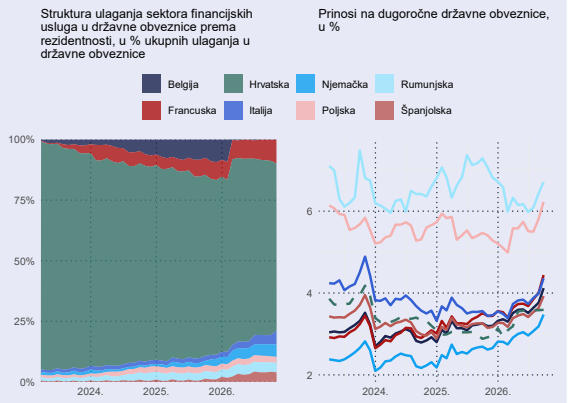


Napomena: Prikazana je struktura ulaganja društava za osiguranje te mirovinskih i UCITS fondova, koji zajedno čine oko 88 % imovine tržišta financijskih usluga.
Izvor: Hanfa

Unatoč smanjenju duracije obveznica, njihova visoka zastupljenost u portfeljima institucionalnih investitora čini kamatni rizik jednim od važnijih izvora sistemskih rizika na kraju drugog tromjesečja 2026. godine. Nakon relativno mirnog početka 2026., prinosi državnih obveznica zabilježili su izraženije oscilacije u drugom tromjesečju pod utjecajem početka procesa monetarnog zatezanja vodećih središnjih banaka, povišene inflacije, ubrzanja fiskalne ekspanzije europskih zemalja i općenitog rasta konkurencije na tržištima dugoročnog javnog duga (slika 3.6.). Domaće državne obveznice pritom su zadržale otpornost uz prinos od 3,59 % na kraju rujna 2026., što je 0,34 p.b. manje od prosjeka europodručja. Rast prinosa kratkoročno se nepovoljno odražava na profitabilnost sektora, kroz pad vrijednosti postojećih obveznickih ulaganja. S druge strane, viši prinosi omogućuju ostvarivanje većih prinosa na nova ulaganja u obveznice te podižu konkurentnost određenih kategorija investicijskih fondova usmjerenih na ulaganje na obveznickim tržištima. Na to ukazuje snažan priljev sredstava u fondove s dospijećem, čija je struktura ulaganja dominantno usmjerena na obveznice[13] (više u poglavlju **Kratkoročni rizici 3.1.**).

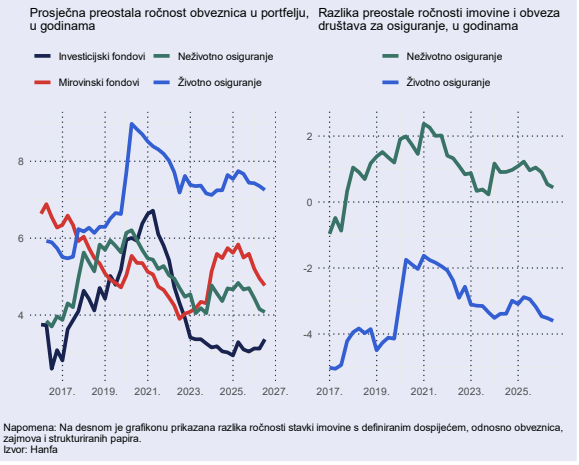
Domaći su institucionalni investitori tijekom drugog tromjesečja 2026. dodatno skratili ročnost obveznickih ulaganja na 4,9 godine (0,2 godine manje u odnosu na kraj 2025.), čime su smanjili osjetljivost portfelja na promjene kamatnih stopa (slika 3.7.). Ipak društva za osiguranje, osobito u segmentu životnih osiguranja, i dalje su izložena riziku ročne neusklađenosti imovine i obveza. Promjene dugoročnih kamatnih stopa stoga mogu imati nepovoljan učinak na njihovu kapitalnu poziciju.

Slika 3.6. Od ulaska Hrvatske u europodručje povećava se izloženost prema državnim obveznicama europskih zemalja



Napomena: Državne obveznice prikazanih zemalja čine oko 90 % ukupnih ulaganja u državne obveznice društava za osiguranje te mirovinskih i UCITS fondova, koji zajedno čine oko 88 % imovine sektora financijskih usluga.
Izvor: Hanfa

Slika 3.7. Smanjivanjem ročnosti obveznickih ulaganja umanjena izloženost sektora kamatnom riziku



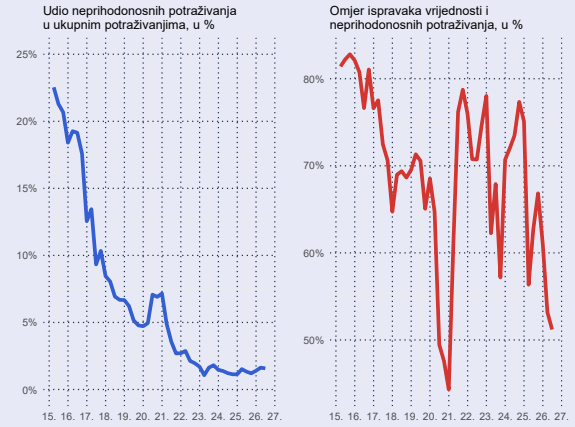
Napomena: Na desnom je grafikonu prikazana razlika ročnosti stavki imovine s definiranim dospijećem, odnosno obveznica, zajmova i strukturiranih papira.
Izvor: Hanfa

Izloženost sektora financijskih usluga kreditnom riziku ostala je stabilna tijekom drugog tromjesečja 2026. U uvjetima relativno povoljnih kretanja domaćeg gospodarstva, uz zadržavanje povijesno visokog kreditnog rejtinga Republike Hrvatske, kreditni rizik sektora zadržan je na niskim razinama. Udio neprihodonosnih potraživanja leasing društava iznosio je 1,6 % na kraju lipnja

[13] Na kraju kolovoza 2026., 88 % imovine fondova s dospijećem bilo je uloženo u obveznice.

2026. uz pokrivenost 51,2 % (slika 3.8.), što odražava dobre poslovne rezultate nefinancijskih poduzeća[14], ali i uzlaznu fazu ciklusa koju karakterizira snažan priljev novih plasmana (više u poglavlju **Kratkoročni rizici 3.1.**). U takvim je okolnostima izloženost sektora kreditnom riziku zadržana na razini s kraja 2025., iako bi recentno usporavanje gospodarske aktivnosti, praćeno s rastom troška zaduživanja, moglo pogoršati sposobnost dužnika za podmirivanje obveza i povećati kreditni rizik sektora u narednom razdoblju.

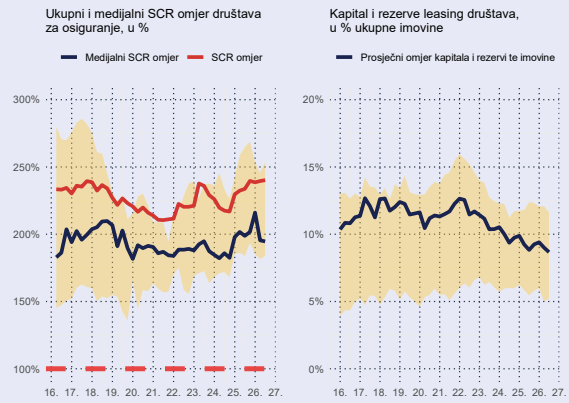
Slika 3.8. Izloženost leasing društava kreditnom riziku zadržana na niskoj razini



Napomena: Posljednji podatak za 2026. odnosi se na kraj drugog tromjesečja 2026. godine.
Izvor: Hanfa

Valutni rizik sektora financijskih usluga ostao je na povijesno niskim razinama i tijekom drugog tromjesečja 2026. godine. Izloženost prema američkom dolaru, glavnom nositelju valutnog rizika, blago je smanjena, pa je udio ulaganja u USD iznosio 8,3 % ukupnih ulaganja[15], odnosno 0,1 p.b. manje nego krajem 2025. godine. Visoka zastupljenost izdavatelja iz europodručja i ulaganja denominiranih u eurima ograničava izloženost sektora recentnim tečajnim oscilacijama koje proizlaze iz povišenih monetarnih neizvjesnosti te trgovinskih napetosti.

Slika 3.9. Stabilne kapitalne pozicije sektora financijskih usluga u drugom tromjesečju 2026. godine



Napomena: Istaknuta područja na grafikonima prikazuju interkvartilne raspone po društvima. Posljednji podatak za 2026. odnosi se na kraj drugog tromjesečja 2026. godine.
Izvor: Hanfa

Kapitaliziranost sektora financijskih usluga zadržana je na visokim i stabilnim razinama tijekom drugog tromjesečja 2026. godine (slika 3.9.). Agregatni SCR omjer društava za osiguranje dodatno je porastao na 240,2 % na kraju drugog tromjesečja 2026., odnosno 2,9 p.b. više u odnosu na kraj 2025., te se i dalje nalazi znatno iznad regulatornog minimuma. Društva iz donjeg dijela distribucije zadržala su relativno stabilne kapitalne pozicije, dok su društva iz gornjeg dijela distribucije dodatno ojačala, što je pridonijelo porastu otpornosti sektora u cjelini. Kapitaliziranost leasing društava u istom je razdoblju blago smanjena, ponajprije zbog povećanog obujma poslovanja i bržeg rasta imovine u odnosu na rast kapitalnih zaliha. Udio kapitala i rezervi u ukupnoj imovini zadržao se na dostatnim razinama te je iznosio 8,7 % na kraju drugog tromjesečja 2026. (0,7 p.b. manje u odnosu na kraj 2025.). Visoke kapitalne zalihe jačaju otpornost sektora, posebice u

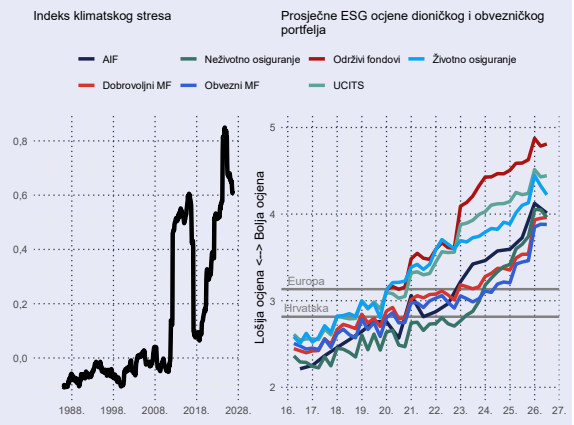
[14] Na kraju drugog tromjesečja, ugovori od strane nefinancijskih poduzeća činili su 74 % vrijednosti svih aktivnih leasing ugovora.

[15] U obzir su uzeta ulaganja društava za osiguranje, mirovinskih i UCITS fondova, koji zajedno čine oko 88 % imovine tržišta financijskih usluga.

uvjetima naglašenih sistemskih rizika povezanih s geopolitičkim napetostima i zadržavanjem kamatnih stopa na povišenim razinama.

Izloženost sektora financijskih usluga klimatskim rizicima blago je smanjena u drugom tromjesečju 2026., uz relativno izraženiju kratkoročnu ranjivost na fizičke u odnosu na tranzicijske rizike. Dugoročni pokazatelji klimatskog stresa za Hrvatsku nastavljaju upućivati na postupno povećanje izloženosti ekstremnim vremenskim nepogodama (slika 3.10.), ponajprije zbog sve intenzivnijih maksimalnih temperatura i učestalijih požara. S obzirom na i dalje niske razine osiguranja od elementarnih nepogoda, materijalizacija fizičkih rizika može generirati znatnije financijske izdatke kućanstava te rezultirati potencijalnim prelijevanjem dijela troškova sanacije na javni sektor, uz moguće nepovoljne učinke na fiskalnu poziciju države. Izloženost tranzicijskim rizicima ostala je stabilna, uz nastavak postupne prilagodbe ulaganja prema izdavateljima s višim standardima održivosti.

Slika 3.10. Klimatski rizici zadržani su na umjerenim razinama



Napomena: Održivi fondovi odnose se na fondove koji se klasificiraju po čl. 8 i čl. 9 SFDR-a. ESG ocjene kreću se u rasponu od 0 do 10, pri čemu viši broj označava bolju ocjenu.
Izvori: E3CI, Bloomberg, Hanfa

OKVIR 1. UMJETNA INTELIGENCIJA KAO IZVOR SISTEMSKIH RIZIKA

Umjetna inteligencija donosi značajne mogućnosti za povećanje produktivnosti i učinkovitosti financijskog sustava, ali istodobno otvara i nove izvore sistemskog rizika. Rizici se mogu prenositi financijskim kanalom, kroz izloženost tehnološkim kompanijama i osjetljivost portfelja na tržišne korekcije, te tehnološkim kanalom, kroz ovisnost o ograničenom broju pružatelja tehnoloških usluga i ograničenu mogućnost njihove zamjene. Izravna izloženost hrvatskog sektora financijskih usluga globalnim AI kompanijama zasad je razmjerno niska, no potencijalni gubici u slučaju tržišne korekcije ne proizlaze samo iz izravnih ulaganja, već i iz neizravnih učinaka prelijevanja preko globalnih tržišta kapitala. Istodobno, sve veća primjena AI-ja u financijskom sektoru i oslanjanje na zajedničke tehnološke pružatelje mogu povećati izloženost kibernetičkim prijetnjama i operativnim rizicima, pri čemu bi incidenti kod ključnih pružatelja usluga mogli istodobno pogoditi veći broj financijskih institucija. Pritom je, za razliku od financijskog kanala, učinke tehnološkog kanala znatno teže kvantificirati zbog povezanosti tehnoloških sustava, brzine tehnoloških promjena i nedostatka usporedivih povijesnih podataka.

Što je AI i kako prenosi rizik na financijski sustav

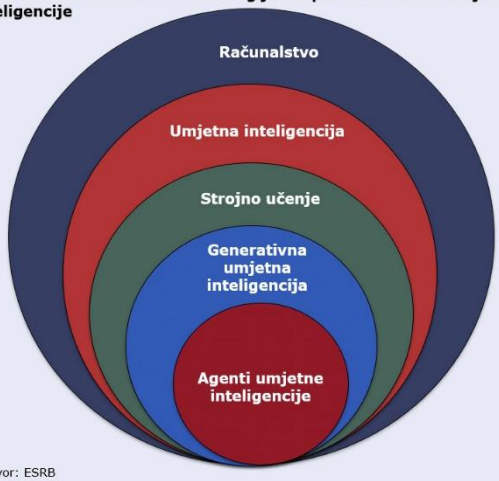
Umjetna inteligencija (engl. *artificial intelligence*, AI) označava strojni sustav koji, uz različite razine autonomije i za eksplicitne i implicitne ciljeve, iz ulaznih podataka zaključuje kako generirati izlazne podatke, poput predviđanja, sadržaja, preporuka ili odluka koji mogu utjecati na fizička ili virtualna okruženja[16]. U širem smislu, pojam obuhvaća algoritme, strojno učenje, generativni AI, uključujući velike jezične modele (engl. *large language models*, LLM), te AI agente koji samostalno izvršavaju zadatke (slika 1.).[17] Prekretnica u široj primjeni AI-ja bila je pojava generativnih modela krajem 2022., koja je omogućila opću primjenu tih tehnologija izvan usko specijaliziranih područja. Za razliku od tradicionalnih algoritama, čija su pravila unaprijed definirana, modeli strojnog učenja tijekom procesa treniranja uče obrasce u podacima. Zbog složenosti tih modela i načina na koji obrađuju podatke, često je otežano razumjeti način na koji obrađuju ulazne podatke te objasniti rezultate i odluke koje na temelju njih donose. Stoga, unatoč velikom potencijalu, primjenu AI-ja prate i određena ograničenja i rizici, uključujući mogućnost generiranja netočnih rezultata te poteškoće u tumačenju i nadzoru njegova rada.

[16] Uredba (EU) 2024/1689 Europskog parlamenta i Vijeća od 13. lipnja 2024. o utvrđivanju usklađenih pravila o umjetnoj inteligenciji (**Akt o umjetnoj inteligenciji**), čl. 3. t. 1.

[17] Cecchetti, S., Lumsdaine, R. L., Peltonen, T. i Sánchez Serrano, A. (2025.): ***Artificial intelligence and systemic risk***, Reports of the Advisory Scientific Committee, br. 16, ESRB, prosinac 2025., okvir 1.

Napredak u području AI-ja otvara mogućnost ostvarivanja značajnih gospodarskih koristi. Primjena AI-ja kroz automatizaciju pojedinih zadataka, povećanje produktivnosti rada, učinkovitiju obradu informacija i inovaciju kroz razvoj novih proizvoda i usluga mogu dugoročno povećati proizvodni potencijal gospodarstva i profitabilnost poduzeća, dok bi u kratkom roku rast ulaganja u AI infrastrukturu mogao dodatno poduprijeti investicijsku aktivnost. U financijskom sustavu AI može pridonijeti učinkovitijoj obradi podataka, kvalitetnijem donošenju odluka i upravljanju rizicima te pravodobnijem prepoznavanju ranjivosti. Međutim, ista svojstva AI-ja koja povećavaju učinkovitost poslovanja, poput brzine obrade i sposobnosti analize velikih količina podataka, mogu pojačati postojeće ranjivosti financijskog sustava i pridonijeti nastanku sistemskog rizika.

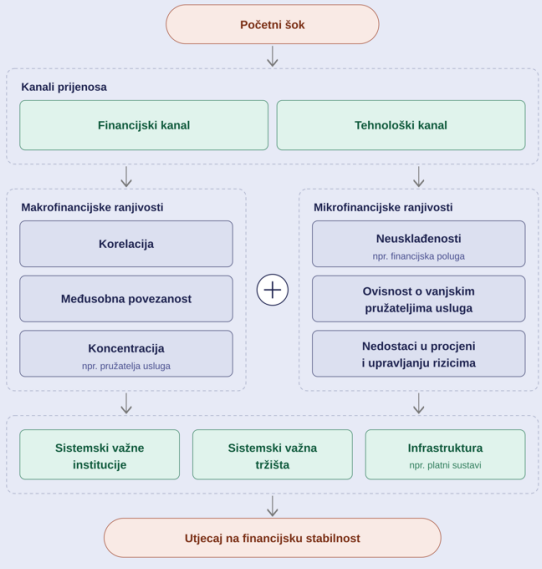
Slika 1. Odnos računalnih tehnologija i naprednih sustava umjetne inteligencije



Izvor: ESRB

Dva su glavna kanala prijenosa sistemskih rizika: financijski i tehnološki (slika 2.). **Financijski kanal** proizlazi iz izloženosti financijskih institucija i drugih ulagatelja poduzećima povezanima s razvojem i primjenom AI-ja. S obzirom na značajna očekivanja i uložena sredstva u razvoj AI modela i rješenja, relativno slabija ostvarenja mogu se nepovoljno odraziti na tržišna vrednovanja poduzeća, a posredno i na vrijednost portfelja tih institucionalnih investitora. Istovremeno, rast troškova financiranja ulaganja u AI infrastrukturu može povećati ranjivost poduzeća, a u slučaju poteškoća u podmirivanju obveza, pridonijeti i širenju poremećaja na kreditna tržišta. **Tehnološki kanal** proizlazi iz primjene AI-ja u poslovanju financijskih institucija i njihove ovisnosti o ograničenom broju pružatelja AI rješenja i povezane infrastrukture. Korištenje sličnih modela može pridonijeti koreliranim odlukama i reakcijama financijskih institucija, dok prekid usluga ili kibernetički napad na ključnog pružatelja može istodobno pogoditi veći broj institucija.

Slika 2. Mehanizmi prijenosa AI-rizika na financijsku stabilnost



Izvori: Bank of England i Hanfa

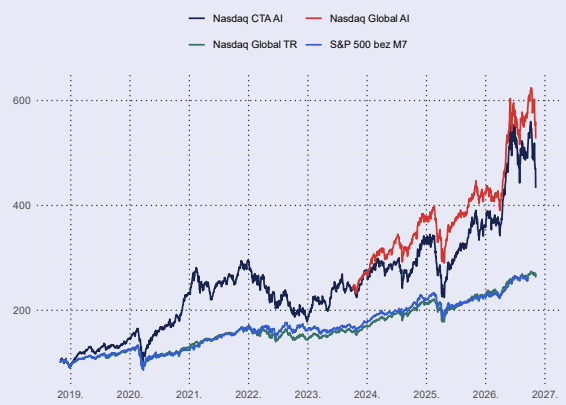
Osim opisanih kanala transmisije, primjena AI-ja može pojačati i postojeće

izvore sistemskog rizika[18], posebno likvidnosnu neusklađenost i osjetljivost na informacije, zajedničke izloženosti, međupovezanost, nezamjenjivost (ovisnost o malom broju pružatelja ključnih usluga) te financijsku polugu i procikličnost. Među značajkama AI-ja koje te izvore najviše pojačavaju izdvajaju se otežano praćenje i nadzor AI sustava, koncentracija pružatelja i uniformnost modela, koji mogu otežati pravodobno prepoznavanje rizika, povećati korelaciju izloženosti i reakcije sudionika te ubrzati širenje poremećaja financijskim sustavom.

Financijski kanal: veličina i koncentracija AI sektora

Brz razvoj umjetne inteligencije i velika očekivanja od njezine buduće primjene sve se snažnije odražavaju na financijska tržišta, osobito kroz rast vrijednosti vodećih tehnoloških kompanija i njihovom sve većom zastupljenosti u vodećim dioničkim indeksima. Udio poduzeća povezanih s AI-jem u tržišnoj kapitalizaciji indeksa S&P 500 povećao se s 26 % u 2022. na 44 % krajem 2025. godine[19]. Taj je rast pritom izrazito koncentriran u malom broju poduzeća, ponajprije u skupini najvećih tehnoloških poduzeća, tzv. Veličanstvenih 7 (engl. *Magnificent 7*, u nastavku M7)[20]. Njihova ključna uloga u razvoju i primjeni AI tehnologija odražava se i u snažnom rastu njihove tržišne vrijednosti tijekom posljednjih godina (slika 3.). Cijene dionica M7 kompanija su od kraja 2022. do kraja rujna 2026. porasle između 2,1 puta kod Microsofta i 15,6 puta kod Nvidije. Posljedično je sedam navedenih kompanija na kraju rujna 2026. činilo više od trećine tržišne kapitalizacije indeksa S&P 500, što je značajan rast u odnosu na kraj 2015. kada su činile svega 12 %.

Slika 3. Kretanje vrijednosti globalnih i AI dioničkih indeksa
Vrijednost indeksa u eurima, 29. 10. 2018. = 100



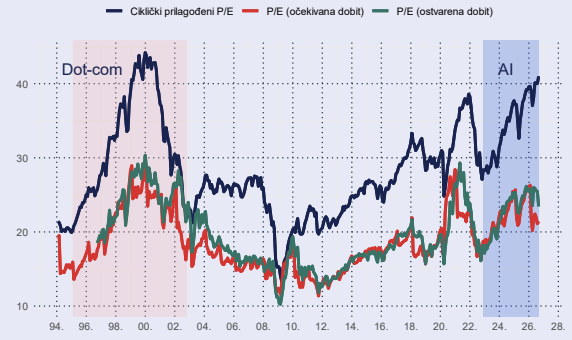
Napomena: Nasdaq Global AI računa se od 3. 10. 2023. te je na taj dan izjednačen s Nasdaq CTA AI.
Izvori: FRED, Nasdaq i S&P Dow Jones Indices

Za procjenu rizika za financijsku stabilnost ključna je utemeljenost tržišnih vrednovanja u poslovnim rezultatima poduzeća, osobito održivosti zarada i profitabilnosti. Visoka vrednovanja odražavaju očekivanja da će se ulaganja u AI infrastrukturu i razvoj usluga pretvoriti u održiv rast prihoda i zarada tehnoloških kompanija i zarada, a prema dostupnim analizama[21], zasad je tek manji dio poduzeća uspio primijeniti AI na način koji donosi mjerljive financijske koristi. Ako se očekivanja investitora ne ostvare, izvjesne su određene korekcije vrednovanja imovine na financijskim tržištima.

[18] Advisory Scientific Committee: ***Artificial intelligence and systemic risk***, prosinac 2025.
[19] Vidjeti Bank of England: *Financial Stability Report December 2025* dostupan na **poveznici**
[20] Riječ je o kompanijama s različitim ulogama u AI ekosustavu: od osiguravanja računalne infrastrukture (Nvidia), preko infrastrukture u oblaku (engl. *cloud*) i razvoja AI usluga (Microsoft, Alphabet i Amazon), do primjene AI-ja u digitalnim platformama i krajnjim proizvodima (Meta, Apple i Tesla).
[21] Vidjeti Challapally, A., Pease, C., Raskar, R. i Chari, P. (2025.), *The GenAI Divide: State of AI in Business 2025*, MIT Project NANDA, srpanj 2025 dostupno na **poveznici**.

Slika 4. Divergencija kratkoročnih i dugoročnih pokazatelja vrednovanja američkog dioničkog tržišta

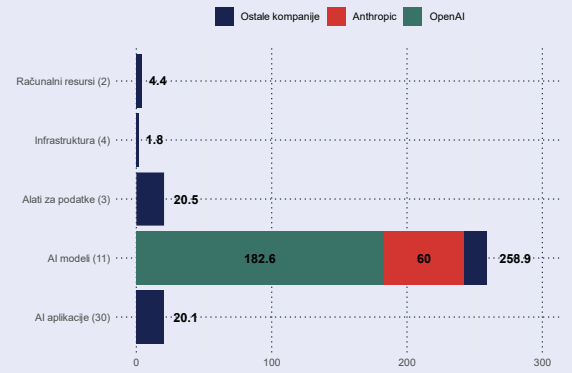
Omjer cijena i zarada za S&P 500, u %



Napomena: Omjer cijene i zarade (P/E) pokazuje koliko puta tržišna cijena dionice premašuje zaradu koju poduzeće ostvaruje po dionici, pri čemu veća vrijednost označuje relativno više vrednovanje u odnosu na ostvarenu zaradu. P/E (očekivana dobit) temelji se na očekivanoj budućoj zaradi poduzeća, dok ciklički prilagođeni P/E pokazuje koliko je puta vrijednost pojedine dionice viša od prosječne desetogodišnje zarade koju poduzeće generira po dionici, gdje veća vrijednost označuje relativno više vrednovanje u odnosu na fundamente.
Izvor: Bloomberg, Hanfa

Slika 5. Prisutna koncentracija prikupljanja kapitala u segmentu razvijanja AI modela

Iznos kapitala koje su prikupile kompanije s popisa Forbes AI 50 (2026.), por razini lanca dodane vrijednosti , u mlrd. USD



Napomena: Broj u zagradi predstavlja broj kompanija u razini lanca dodane vrijednosti.
Izvor: Forbes, Hanfa

Taj je rizik osobito važan za američko dioničko tržište, čija vrednovanja su pod snažnim utjecajem tehnoloških kompanija dosegnula povijesne maksimume sredinom 2026. godine. Ciklički prilagođen omjer cijena i zarada (engl. *cyclically adjusted price-to-earnings ratio,* CAPE) za američko dioničko tržište ukazuje na visoku razinu tržišnog vrednovanja u odnosu na dugoročne zarade (slika 4.), a takva razina nije zabilježena od početka 2000-ih i dot-com razdoblja[22] kada su očekivanja povezana s razvojem interneta potaknula snažan rast cijena tehnoloških dionica. S obzirom na globaliziranost financijskog sustava i dominantan utjecaj američkog tržišta kapitala na ostala tržišta, učinci eventualnih korekcija na američkom tržištu ne bi nužno ostali ograničeni na to tržište. Takva bi se kretanja mogla odraziti i na europska tržišta, šire uvjete financiranja i gospodarsku aktivnost zemalja europodručja[23], a zbog međupovezanosti domaćeg i međunarodnih tržišta kapitala, i na domaći financijski sustav[24].

Uz rast tržišnog financiranja, u snažnom porastu je i privatno financiranje AI kompanija koje nisu uvrštene na dioničko tržište. Pedeset vodećih privatnih AI kompanija je tijekom 2025. prikupilo gotovo 306 mlrd. USD, pri čemu je glavnina financiranja izrazito koncentrirana u dvije kompanije (slika 5.)[25]. Posljedično, prikupljanje kapitala koncentrirano je, ne samo geografski, nego i u pojedinim segmentima lanca vrijednosti AI sektora[26]. Time je naglašen idiosinkratski rizik kroz neizvjesnost poslovnih modela privatnih kompanija koji može postati sistemske naravi u slučaju prelijevanja šokova na ostatak tržišta. Također, privatne kompanije koje

[22] Dot-com balon označava razdoblje snažnog rasta valuacija tehnoloških kompanija krajem 1990-ih, potaknuto visokim očekivanjima o gospodarskom potencijalu interneta, koje je kulminiralo naglom korekcijom cijena dionica početkom 2000-ih.

[23] Vidjeti ECB-ov blog: *The AI boom: rational enthusiasm or the next dot-com bubble?* dostupan na **poveznici**.

[24] Vidjeti Financijsku stabilnost br. 5, *Okvir 1. Zaraza ili međuovisnost? Što povezuje hrvatsko i svjetska tržišta kapitala?* dostupan na **poveznici**.

[25] **Forbes: 2026 AI 50**, objavljeno 16. travnja 2026. Čak 79 % ukupnog financiranja u 2025. odnosio se na OpenAI i Anthropic.

[26] Kompanije sa sjedištem u SAD-u prikupile su oko 97 % ukupnog kapitala, a kreatori AI modela 84,7 %, dok su brojnije kompanije u segmentu razvijanja AI aplikacija prikupile 6,6 % ukupnog privatnog financiranja.

planiraju ući u IPO fazu generiraju visoka očekivanja u pogledu tržišne kapitalizacije koja bi mogla dosegnuti rekordne vrijednosti, što bi dodatno moglo pridonijeti rastu tržišnih vrednovanja i rizika tržišne korekcije u slučaju neispunjenja visokih očekivanja investitora.

Ubrzana izgradnja AI infrastrukture sve se više financira zaduživanjem, čime dodatno raste povezanost tehnološkog i financijskog sektora. Procjene[27] upućuju na to da bi izgradnja podatkovnih centara od 2026. do 2028. mogla zahtijevati oko 3,2 bil. USD, od čega bi 55 % trebalo financirati dugom, dok bi se ostatak financirao privatnim kreditima (engl. *private credit*). Pružatelji računalstva u oblaku velikih razmjera (engl. *hyperscalers*) u 2025. izdali su obveznice u vrijednosti višoj od 100 mlrd. USD[28], no dio zaduživanja odvija se izvan njihovih bilanci kroz kompleksnije financijske aranžmane koji uključuju veći broj dionika iz financijskog sektora. Osim kompleksnosti i manjka transparentnosti, navedeni aranžmani povećavaju izloženost banaka i institucionalnih investitora riziku projekta gradnje infrastrukture i jačaju povezanost financijskog sektora s tehnološkim kompanijama. Rastuća ulaganja u AI financiraju se pretežno dugoročnim zaduživanjem, uglavnom radi izgradnje podatkovnih centara. Brzo zastarijevanje infrastrukture zbog razvoja novih generacija čipova moglo bi smanjiti vrijednost kolaterala i ugroziti sposobnost servisiranja duga[29].

Međusobna ulaganja AI kompanija stvaraju dodatne financijske veze koje mogu pridonijeti prijenosu rizika među kompanijama u slučaju usporavanja investicijskog ciklusa. Primjerice, proizvođači čipova i pružatelji usluga računalstva u oblaku ulažu u kompanije koje razvijaju AI modele, koje potom dio prikupljenih sredstava koriste za nabavu čipova i računalnih kapaciteta upravo od svojih ulagača. Na taj se način ulaganja jednih kompanija pretvaraju u prihode drugih, čime se dodatno učvršćuju njihove međusobne financijske veze. Međunarodni monetarni fond (MMF) upozorava na sve veću zastupljenost takvih oblika kružnog financiranja u lancu vrijednosti umjetne inteligencije[30]. U slučaju usporavanja trenutnog investicijskog ciklusa, smanjenje ulaganja moglo bi pokrenuti povratnu spregu: slabija dostupnost kapitala ograničila bi mogućnosti financiranja AI kompanija, koje bi bile prisiljene smanjiti potrošnju na čipove i računalne kapacitete. To bi se odrazilo na prihode dobavljača, ali i na vrijednost njihovih vlasničkih udjela u AI kompanijama, čime bi se negativni učinci prenijeli kroz cijeli lanac vrijednosti umjetne inteligencije.

Izloženost domaćeg sektora financijskih usluga

Iz perspektive hrvatskog sektora financijskih usluga, izloženost prema globalno poznatim AI kompanijama

[27] Vidjeti Bank of England: *Financial Stability Report – July 2026* dostupan na **poveznici**.

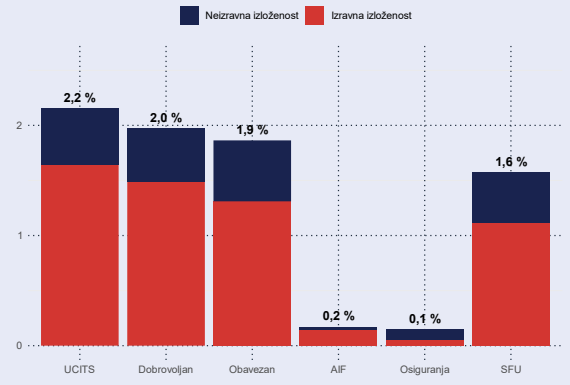
[28] BIS: ***Financing the AI infrastructure boom: on- and off-balance sheet borrowing***, BIS Quarterly Review, ožujak 2026. Navedeni su Alphabet, Amazon, Meta, Microsoft i Oracle.

[29] Vidjeti govor Tobiasa Adriana na *ECB Sintra Forum on Central Banking*, dostupno na **poveznici**.

[30] Vidjeti IMF: *Global Financial Stability Report, April 2026* dostupan na **poveznici**.

sredinom 2026. godine se pokazala razmjerno niskom s izloženošću oko 1,6 % (slika 6.). Pri tome relativno najveći udio izloženosti dolazi putem izravnih ulaganja, dok su neizravni kanali relativno manje izraženi. Ukupna izloženost među sektorima je također ograničena s obzirom na značajnu usmjerenost portfelja prema državnim obveznicama te domaćem i EU tržištu. Sektor UCITS fondova se izdvaja s relativno najvećom izloženošću od preko 2 % imovine, a usporediva razina izloženosti je zabilježena kod obveznih i dobrovoljnih mirovinskih fondova, dok neznatnu izloženost imaju AIF-ovi i društva za osiguranje. U usporedbi s prosjekom EU zemalja[31], ukupna izloženost domaćeg sektora financijskih usluga je znatno niža, no potencijalni utjecaj prelijevanja negativnih kretanja na domaće subjekte je i dalje značajan.

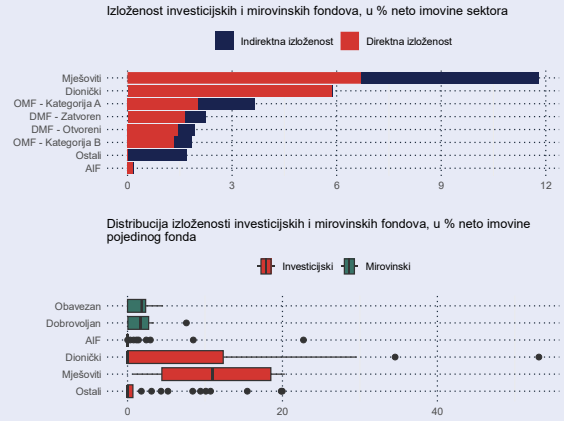
Slika 6. Domaći sektor financijskih usluga nisko izložen
Izloženost domaćih sektora prema dionicama globalnih AI kompanija, u % ukupne imovine sektora



Napomena: Iznos indirektne izloženosti procijenjen je na temelju ulaganja domaćih subjekata nadzora u investicijske fondove koji su izloženi dionicama kompanija Veličanstvene sedmorke, čija tržišna kapitalizacija krajem listopada čini gotovo 73 % ukupne tržišne kapitalizacije svih AI kompanija obuhvaćenih analizom.
Izvor: Hanfa

Iako je ukupna izloženost sektora financijskih usluga razmjerno niska, pojedini tržišni segmenti, poput mješovitih i dioničkih fondova, su ipak relativno više izloženi dionicama AI kompanija (slika 7.). Izloženost mirovinskih fondova je relativno niska pri čemu prednjači kategorija A s 3,6 % s obzirom na veću portfeljnu izloženost dionicama i investicijskim fondovima. S aspekta distribucije izloženosti pojedinih subjekata zabilježen je nizak prosjek izloženosti po kategorijama investicijskih i mirovinskih fondova, izuzev nekolicine subjekata sa značajnijim izloženostima prema dionicama AI kompanija, posebice u segmentu dioničkih fondova.

Slika 7. Relativno visoka izloženost je zabilježena kod mješovitih i dioničkih fondova, no prosječna izloženost po sektorima ostaje niska



Izvor: Hanfa

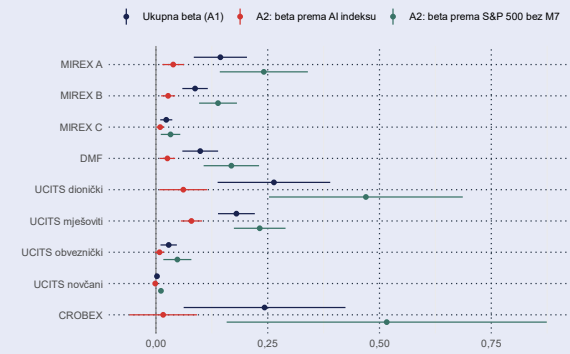
Prelijevanje sistemskog rizika putem tržišnog kanala

Kretanja cijena dionica AI kompanija mogu se na domaći sektor financijskih usluga odraziti i neizravno. Zbog velike zastupljenosti u svjetskim dioničkim indeksima, AI kompanije značajno pridonose njihovim ukupnim promjenama, što se može odraziti i na vrijednost ostalih dionica u portfeljima domaćih institucionalnih investitora. Osjetljivost kretanja cijena udjela

[31] Krajem lipnja 2024. godine izloženost EU fondova AI kompanijama je iznosila između 12 % i 14 %, dok je u nekim zemljama poput Nizozemske zabilježena natprosječna razina izloženosti među sektorima preko 30 %. Više pogledati na ***Artificial intelligence in EU investment funds: adoption, strategies and portfolio exposures*** i ***Dutch financial institutions invest heavily in volatile tech stocks***.

domaćih investicijskih i mirovinskih fondova mjeri beta koeficijent, koji pokazuje koliko se u prosjeku promijeni prinos fonda kad se prinos AI dionica promijeni za jedan postotni bod[32]. Procjene na temelju tjednih prinosa pokazuju da je ukupna osjetljivost najveća kod dioničkih UCITS fondova (0,26) i domaćeg dioničkog tržišta (0,24), dok za obvezne mirovinske fondove kategorije A i B iznosi 0,14, odnosno 0,10 (slika 8.).

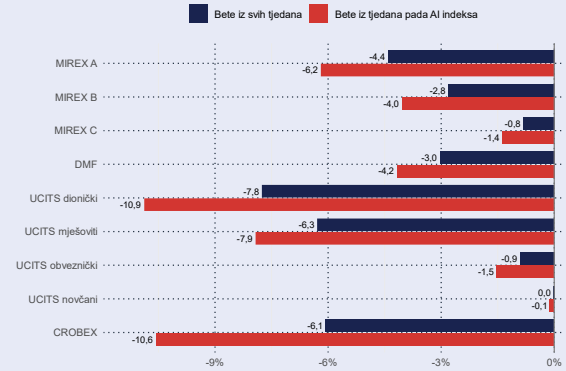
Slika 8. Osjetljivost domaćih fondova na AI dionice proizlazi iz kretanja šireg tržišta
Beta s 95-postotnim intervalom pouzdanosti



Napomena: Bete su procijenjene iz tjednih prinosa u eurima. A1: prinos indeksa fonda regresiran je na prinos AI indeksa (Nasdaq CTA AI), pa beta obuhvaća i kretanje tržišta koje prati AI dionice. A2: regresija istodobno na AI indeks i S&P 500 bez sedam najvećih tehnoloških kompanija, pa se osjetljivost razdvaja na AI dionice i ostatak tržišta; te se bete koriste u scenariju (slika 9.).
Izvori: FRED, Nasdaq, S&P Dow Jones Indices, ZSE i Hanfa

Osjetljivost domaćih fondova proizlazi prvenstveno iz međupovezanosti svjetskih tržišta kapitala, a ne iz izravne izloženosti fondova prema AI kompanijama. Kad se iz prinosa AI dionica ukloni dio koji se kreće zajedno sa svjetskim tržištem, beta B kategorije mirovinskih fondova prema preostalom, AI-specifičnom dijelu iznosi 0,03, a prema ostatku tržišta 0,14 (slika 8.). To odražava razmjerno nisku zastupljenost AI kompanija u portfeljima domaćih fondova. Stoga oni u razdobljima snažnijeg rasta AI dionica zaostaju za svjetskim tržištem, ali su manje izloženi i gubicima kada padaju samo te dionice. Ipak, osjetljivost domaćih fondova veća je u razdobljima pada cijena AI dionica, što odražava nelinearnu narav sistemskih rizika u razdobljima povišenog tržišnog stresa. Procijenjena samo na tjednima u kojima su AI dionice pale, ukupna beta kategorije A iznosi 0,25 umjesto 0,16, a kategorije B 0,15 umjesto 0,10.

Slika 9. U scenariju cjenovne korekcije AI sektora i domaći sektor bi zabilježio gubitke
Promjena vrijednosti indeksa uz pad AI dionica od 40 % i ostatka američkog tržišta od 10 %



Napomena: Promjena je izračunana iz beta modela A2 (slika 8.) procijenjenih na svim tjednima, odnosno samo na tjednima u kojima je AI indeks pao.
Izvori: FRED, Nasdaq, S&P Dow Jones Indices, ZSE i Hanfa

Učinci simulirane tržišne korekcije na ulagatelje i domaće tržište

Za potrebe ove analize provedena je simulacija osjetljivosti domaćih investitora na izolirane tržišne šokove, bez pretpostavki o istodobnim makroekonomskim poremećajima. Riječ je o hipotetskom scenariju koji ne

[32] Bete su procijenjene iz tjednih prinosa indeksa kategorija obveznih mirovinskih fondova (MIREX), dobrovoljnih mirovinskih fondova i kategorija UCITS fondova u eurima, u razdoblju od studenoga 2018. do kraja listopada 2026. Indeksi fondova izračunani su iz dnevnih cijena udjela ponderiranih neto imovinom fondova. AI dionice predstavlja indeks Nasdaq CTA Artificial Intelligence, a svjetsko tržište indeks Nasdaq Global (neto ukupni prinosi, preračunati u eure). AI-specifični faktor definiran je kao rezidual regresije prinosa AI indeksa na prinose indeksa Nasdaq Global. Primijenjeni su tjedni log-prinosi od srijede do srijede radi ublažavanja učinka nesinkronog vrednovanja zbog različitog radnog vremena burzi u Europi i u SAD-u, procijenjena je Dimsonova korekcija s jednim tjednim pomakom te standardne pogreške prema Neweyju i Westu. Vrijednosti indeksa preuzete su iz baze FRED Banke federalnih rezervi St. Louisa i sa Zagrebačke burze.

predstavlja prognozu niti odražava očekivanja o budućim tržišnim kretanjima, već služi procjeni mogućih učinaka nepovoljnih tržišnih okolnosti na domaći financijski sektor. U takvom malo vjerojatnom, ali mogućem scenariju pada cijena AI dionica za 40 % i ostatka američkog tržišta za 10 %, domaći mirovinski i investicijski fondovi bi također zabilježili gubitke, koji bi pak ostali relativno umjereni (slika 9.). Provedena simulacija utemeljena je na procijenjenim povijesnim elastičnostima prinosa domaćih fondova na kretanja AI dionica i šireg tržišta. Riječ je o korekciji, usporedivoj s padovima tehnoloških dionica tijekom 2000. i 2022. godine. Omjer padova odgovara dvjema godinama snažne korekcije tehnoloških dionica[33]. U tom simuliranom scenariju bi se imovina obveznih mirovinskih fondova smanjila za oko 823 mil. EUR, dobrovoljnih mirovinskih fondova za 56 mil. EUR, a UCITS fondova za 115 mil. EUR. Rezultati simulacije pokazuju da su procijenjeni gubici znatno veći od onih koji proizlaze isključivo iz izravnih ulaganja u AI kompanije. Primjerice, uz izloženost od 3,6 %, pad AI dionica od 40 % smanjio bi imovinu fondova kategorije A za 1,4 %, dok ukupni procijenjeni gubitak u simulaciji iznosi 4,4 %, što proizlazi iz pada vrijednosti ostalih dionica u portfeljima i povezanosti domaćeg tržišta sa svjetskim, zbog čega bi i CROBEX u ovom scenariju pao za 6,1 %. Pritom je važno naglasiti da se procjene temelje na povijesno utvrđenim elastičnostima i zadanim pretpostavkama, te ne predstavljaju prognozu budućih gubitaka. Pritom bi gubici u nepovoljnim okolnostima mogli biti i veći, što potvrđuju i rezultati ovogodišnjeg makroekonomskog stresnog testa, u kojem su zabilježeni izraženiji učinci. Naime, za razliku od prikazane simulacije koja obuhvaća izolirane tržišne šokove i procjenjuje njihove učinke na temelju beta koeficijenata, stresno testiranje uzima u obzir i nelinearnosti, prelijevanje rizika te dodatne kanale prijenosa šokova koji proizlaze iz šireg makroekonomskog i financijskog okružja[34].

Za financijsku stabilnost važniji od samih gubitaka ulagatelja mogu biti njihovi učinci na ponašanje ulagatelja i tržišnu likvidnost. Budući da UCITS fondovi omogućuju dnevni otkup udjela, veći odljevi mogli bi potaknuti prodaju likvidnije imovine, uključujući domaće dionice i obveznice, i dodatno pritisnuti cijene na relativno plitkom domaćem tržištu. Ipak, s obzirom na to da dionički i mješoviti UCITS fondovi upravljaju s oko 1,0 mlrd. EUR imovine, što čini svega 2,0 % ukupne imovine sektora financijskih usluga, učinak otkupa na sustav u cjelini bio bi razmjerno ograničen. Obvezni mirovinski fondovi nisu izloženi iznenadnim otkupima sredstava, pa gubici ne bi izazvali prisilnu prodaju imovine, ali bi izravno smanjili vrijednost mirovinske štednje. Učinak na članove koji se približavaju odlasku u mirovinu, a koji se najvećim dijelom nalaze u kategoriji C,

[33] U 2000., prvoj godini pucanja dot-com balona, indeks Nasdaq Composite pao je 39 %, a S&P 500 10 %, a u 2022., uz nagli rast kamatnih stopa, indeks Nasdaq CTA AI pao je 41 %, a S&P 500 bez M7 10 %. Gubitak domaćih fondova u navedenom stresnom scenariju procijenjen je iz beta prema indeksima Nasdaq CTA AI i S&P 500 bez M7 procijenjenih na cijelom uzorku.

[34] Metodološki koncept stresnog testiranja je opisan u **Okviru 1. Simulacija efekata koronakrize na stabilnost sektora financijskih usluga**, a ovogodišnji scenarij i rezultati u **Financijskoj stabilnost br. 5**.

ograničen je konzervativnom strukturom ulaganja fondova, čiji gubitak bi u navedenom scenariju iznosio 0,8 %.

Tehnološki kanal: upotreba AI-ja i ovisnost o pružateljima

Primjena AI-ja u financijskom sektoru može povećati učinkovitost poslovanja, ali i istodobno stvoriti nove izvore ranjivosti. Rizici primjene AI-ja proizlaze ponajprije iz ovisnosti o malom broju pružatelja tehnoloških usluga i ograničenih mogućnosti njihove zamjene. Poremećaj u radu ključnog pružatelja usluga ili pogreška u radu modela tako bi mogli istodobno pogoditi veći broj institucija, a ako bi pritom zahvatili ključne funkcije financijskog sustava ili se proširili na druge njegove dijelove, posljedice bi mogle poprimiti sistemski značaj.

Podaci o primjeni AI-ja u financijskom sektoru uglavnom se temelje na anketnim istraživanjima regulatornih tijela. Interpretaciju rezultata dodatno otežava brz razvoj tehnologije i raznolikost oblika primjene, stoga istraživanja vjerojatno podcjenjuju stvarnu upotrebu AI-ja. Prema istraživanju EBA-e iz 2025., AI je koristilo 92 % banaka u EU-a, dok ga je 8 % banaka koristilo u pilot projektima[35]. Prema izvješću EIOPA-e, u sektoru osiguranja je u 2024. AI koristilo 50 % anketiranih društava za neživotna osiguranja i 24 % društava za životna osiguranja[36]. Novije istraživanje EIOPA-e, provedeno 2025.[37], pokazuje da je 65 % anketiranih osiguratelja već aktivno primjenjivalo generativni AI, dok je dodatnih 23 % planiralo njegovu primjenu. Prema istom istraživanju, u Hrvatskoj je sredinom 2025. generativni AI primjenjivalo 29 %, dok je 57 % planiralo njegovu primjenu u sljedeće tri godine. Preostalih 14 % društava nije koristilo generativni AI, niti je planiralo njegovu primjenu. Takvi rezultati upućuju na to da je primjena generativnog AI-ja u Hrvatskoj još u fazi planiranja i testiranja, ali i da postoji znatan potencijal za njezino širenje u budućem razdoblju.

Primjena AI-ja na tržištima vrijednosnih papira relativno je manje raširena. Prema anketi ESMA-e iz 2025.[38], 53 % investicijskih društava i društava za upravljanje nije prijavilo nijedan slučaj primjene AI-ja, ni u operativnom poslovanju ni u fazi razvoja ili testiranja. Među prijavljenim slučajevima primjene prevladavali su alati za podršku internim procesima, poput izrade i sažimanja tekstova, internih asistenata te obrade i provjere kvalitete podataka. Istraživanje je ujedno pokazalo visoku koncentraciju pružatelja tehnoloških usluga: 62 % anketiranih subjekata oslanjalo se isključivo na komercijalna rješenja računalstva u oblaku za AI infrastrukturu, pri čemu se 41 % oslanjao na samo jednog pružatelja[39]. Pritom je samo oko 8 % pružatelja navedenih u anketi imalo sjedište u EU-u.

Rizici povezani s koncentracijom pružatelja tehnoloških usluga prepoznati su i u okviru Uredbe o digitalnoj

[35] Više o istraživanju je dostupno na **poveznici**.
[36] Vidjeti izvještaj EIOPA-e Report on the digitalisation of the European insurance sector dostupan na **poveznici**.
[37] Vidjeti izvještaj EIOPA-e *Generative AI Market Survey: Outlook, Use Cases and Risk Management* dostupan na **poveznici**.
[38] Vidjeti ESMA: *AI adoption and trends in securities markets: EU evidence* dostupno na **poveznici**.
[39] Microsoft je bio glavni vanjski pružatelj AI-povezanih usluga za gotovo polovicu ispitanika, a slijedili su OpenAI i Amazon Web Services.

otpornosti (DORA)[40]. U studenom 2025. su europska nadzorna tijela prvi put odredila 19 ključnih trećih strana pružatelja kritičnih usluga koje se temelje na informacijskoj i komunikacijskoj tehnologiji na razini EU-a, među kojima su i veliki pružatelji računalstva u oblaku, poput Microsofta, Amazon Web Services-a i Google Clouda. Njihovo određivanje temelji se, među ostalim, na mogućem sistemskom učinku poremećaja u pružanju usluga i ograničenoj mogućnosti zamjene tih usluga.

Kibernetička sigurnost

Visok stupanj digitalizacije i međusobne povezanosti čini financijski sustav ranjivim na kibernetički rizik, koji je prepoznat kao jedan od izvora sistemskog rizika, a dodatno je naglašen recentnim napretkom u razvijanju naprednijih AI modela (engl. *frontier AI models; FAIM*). U kontekstu kibernetičke zaštite, FAIM modeli mogu pomoći u samostalnom otkrivanju prethodno nepoznatih ranjivosti operativnih sustava i softvera pri čemu se znatno skraćuje vrijeme potrebno za njihovo adresiranje. Međutim, ista tehnologija napadačima omogućuje provođenje sofisticiranih kibernetičkih napada uz relativno niske troškove i potrebno tehničko predznanje, čime se značajno povećava broj potencijalnih napadača. ESRB stoga razvoj tih modela prepoznaje kao mogući izvor sistemskog rizika[41]. Posebnu zabrinutost stvara mogućnost da jedan napad istodobno pogodi više financijskih institucija koje koriste zajedničke pružatelje usluga. Budući da napadači traže najslabiju kariku, neujednačene obrambene sposobnosti postaju ranjivost cijelog sustava[42].

Kibernetičke sposobnosti FAIM modela brzo se razvijaju. Modeli objavljeni krajem 2025. u prosjeku su riješili 34 % zadataka u simuliranom napadu na korporativnu mrežu, dok su najnoviji modeli uspjeli riješiti sve zadatke u testu[43]. Važno je naglasiti i da se razvoj naprednih modela umjetne inteligencije odvija u okolnostima pojačanih geopolitičkih napetosti, pri čemu njihova dostupnost i kontrola postaju pitanje nacionalne sigurnosti. Koncentracija kompanija sposobnih za razvoj FAIM modela u trećim zemljama povećava stratešku ovisnost EU-a o stranim pružateljima tehnologije. Moguća ograničenja izvoza dodatno bi mogla otežati pristup tim modelima i povezanim uslugama, što bi povećalo izazove u održavanju kibernetičke otpornosti europskog financijskog sustava.

Mogućnosti politike

Razvoj umjetne inteligencije ne zahtijeva nužno uvođenje novih makrobonitetnih instrumenata, već prilagodbu postojećih okvira za praćenje i ublažavanje sistemskih rizika. S obzirom na brz razvoj tehnologije i neizvjesnost u pogledu njezinih dugoročnih učinaka, prvi korak

[40] Uredba (EU) 2022/2554 Europskog parlamenta i Vijeća od 14. prosinca 2022. o digitalnoj operativnoj otpornosti za financijski sektor i izmjeni uredbi (EZ) br. 1060/2009, (EU) br. 648/2012, (EU) br. 600/2014, (EU) br. 909/2014 i (EU) 2016/1011, SL L 333 dostupna na **poveznici**.

[41] Vidjeti ESRB: *Addressing frontier AI models with cyber capabilities from a financial stability perspective*; dostupno na **poveznici**.

[42] Adrian (2026.), op. cit.

[43] ESRB (2026.), op. cit. Test britanskog instituta za sigurnost AI-ja (UK AI Security Institute) simulira napad na korporativnu mrežu u 32 koraka, za koji bi čovjeku trebalo oko 20 sati.

leži u pravodobnom prepoznavanju novih izvora ranjivosti i mogućih kanala prijenosa na financijski sustav. U tom smislu sustavno praćenje izravne i neizravne izloženosti sektora financijskih usluga prema AI kompanijama, kao i procjena osjetljivosti portfelja institucionalnih investitora na kretanja u tehnološkom sektoru predstavljaju podlogu za procjenu tržišnih rizika povezanih sa razvojem AI-ja. Za procjenu tehnoloških rizika ključno je praćenje koncentracije pružatelja računalnih i drugih IKT usluga te razine oslanjanja financijskih institucija na AI rješenja. Dodatno, provedba vježbi stresnog testiranja koje obuhvaćaju nagle tržišne korekcije i prekid pružanja ključnih tehnoloških usluga omogućuje stjecanje uvida u razinu pripremljenosti financijskog sektora na sistemske šokove. Korekcija vrednovanja vodećih globalnih tehnoloških kompanija, uslijed povećanih operativnih troškova te izraženijih regulatornih pritisaka, bila je jedan od elemenata u konstrukciji stresnog scenarija u ovogodišnjoj makrobonitetnoj vježbi stresnog testiranja (više informacija dostupno je u publikaciji **Financijska stabilnost, br. 5**).

Za AI rizike koji se šire financijskim kanalom ključni su alati za očuvanje dostatne razine kapitala i likvidnosti. Konkretno, ESMA-ine smjernice o alatima za upravljanje likvidnošću[44] namijenjene su rješavanju pitanja dostatne likvidnosti UCITS fondova i otvorenih AIF-ova. Aktiviranjem naknada za otkup (engl. *redemption fees*) i prilagodba cijene udjela (engl. *swing pricing*) prebacuje se trošak otkupa na ulagatelje koji izlaze iz fonda i tako usporavaju naglo povlačenje sredstava nakon tržišne korekcije. Savjetodavni znanstveni odbor ESRB-a (engl. *Advisory Scientific Committee* ATC) predlaže i podizanje transparentnosti uvođenjem oznaka za UCITS fondove čiju strategiju određuje AI[45].

Rizici koji se prenose tehnološkim kanalom uglavnom proizlaze iz ovisnosti financijskih institucija o vanjskim pružateljima IKT usluga i AI rješenja te njihove koncentracije. Regulatorni okvir za upravljanje tim rizicima čine Uredba DORA i **Akt o umjetnoj inteligenciji**. DORA uređuje upravljanje rizicima povezanima s korištenjem IKT usluga trećih strana i predviđa vođenje registara takvih pružatelja. Međutim, ti registri ne obuhvaćaju nužno cjelokupni lanac pružatelja tehnoloških usluga čime su iz analize potencijalno isključene kompanije koje razvijaju AI modele. Akt o umjetnoj inteligenciji svrstava sustave za procjenu rizika i određivanje cijena u životnom i zdravstvenom osiguranju u visokorizične AI sustave implicirajući povišen operativni i pravni rizik u osiguratelnom sektoru.[46] Regulatorna tijela sve više naglašavaju potrebu prilagodbe upravljačkih okvira[47] i kompetencija sudionika[48] financijskog sustava rizicima i izazovima povezanima s

[44] ESMA: ***Guidelines on liquidity management tools of UCITS and open-ended AIFs***, 2026.
[45] Cecchetti i sur. (2025.), op. cit. Navedeno se odnosi na označavanje UCITS fondova čija strategija se slijedi uz pomoć AI-a i društava za osiguranje ili njihovih proizvoda koji koriste AI za izračunavanje tehničkih pričuva ili cijene proizvoda uz pomoć AI-a.
[46] Uredba (EU) 2024/1689, op. cit., Prilog III., točka 5. podtočka (c).
[47] EIOPA: ***Opinion on artificial intelligence governance and risk management***, EIOPA-BoS-25-360, 6. kolovoza 2025.
[48] Anand i sur. (2026.), op. cit.

primjenom novih tehnologija, osobito umjetne inteligencije. ESRB naglašava potrebu za koordiniranim odgovorom na razini EU-a, prilagodbom testiranja otpornosti i mjera pripravnosti te razmjenom informacija o ranjivostima u svrhu jačanja kibernetičke otpornosti financijskog sustava[49].

Zaključno

Umjetna inteligencija nudi značajne prilike za financijski sektor. Može povećati produktivnost, unaprijediti upravljanje rizicima i pridonijeti kvalitetnijem donošenju odluka. Istodobno, njezina sve šira primjena otkriva nove rizike, a može i pojačati postojeće ranjivosti. Cilj nositelja politika i regulatora nije ograničiti ili usporiti inovacije, već osigurati da njihovu primjenu prate odgovarajuće upravljanje rizicima, učinkovit nadzor i otpornost financijskog sustava.

Rezultati provedene analize upućuju na to da je izloženost domaćeg sektora financijskih usluga poduzećima povezanima s AI-jem u prosjeku niska. Ipak, specifična obilježja aktualnog AI ciklusa, ponajprije koncentracija vrijednosti i financiranja u malom broju poduzeća, te kombinacija rastuće tehnološke ovisnosti i intenziviranja kibernetičkih napada kojima su institucije izložene, zahtijevaju pomno praćenje. Pritom rizici ne proizlaze isključivo iz izravnih ulaganja u AI poduzeća, već se mogu ostvariti i neizravno, kroz promjene tržišnog vrednovanja imovine u portfeljima, ovisnost o zajedničkim pružateljima usluga te povećane izloženosti kibernetičkim napadima.

Reference:

Adrian, Tobias. 2026. “Artificial Intelligence and Financial Stability.”

Andersson, Malin, Johannes Breckenfelder, Stefano Corradin, Kalin Nikolov, and Maria Antonietta Viola. 2026. “The AI Boom: Rational Enthusiasm or the Next Dot-Com Bubble?” *The ECB Blog*.

Bagattini, Giulio, and Federico Piazza. 2025. “Artificial Intelligence in EU Investment Funds: Adoption, Strategies and Portfolio Exposures.” *ESMA TRV Risk Analysis*.

Bank of England. *Financial Stability Report: December 2025*.

Bank of England. *Financial Stability Report: July 2026*.

Cecchetti, Stephen, Robin L. Lumsdaine, Tuomas Peltonen, and Antonio Sánchez Serrano. 2025. *Artificial Intelligence and Systemic Risk*. Advisory Scientific Committee, no. 16. European Systemic Risk Board.

Challapally, Aditya, Chris Pease, Ramesh Raskar, and Pradyumna Chari. 2025. *The GenAI Divide: State of AI in Business 2025*. MIT Project NANDA.

De Nederlandsche Bank. 2025. “Dutch Financial Institutions Invest Heavily in Volatile Tech Stocks.”

Eren, Egemen, Ingomar Krohn, and Karamfil Todorov. 2026. “Financing the AI Infrastructure Boom: On- and Off-Balance Sheet Borrowing.” *BIS Quarterly Review*.

European Banking Authority. 2025. *Rising Application of AI in EU Banking and Payments Sector*.

European Insurance and Occupational Pensions Authority. 2024. *Report on the*

[49] ESRB (2026.), op. cit.

Digitalisation of the European Insurance Sector.

European Insurance and Occupational Pensions Authority. 2025. *Opinion on Artificial Intelligence Governance and Risk Management*. EIOPA-BoS-25-360.

European Insurance and Occupational Pensions Authority. 2026. *Generative AI Market Survey: Outlook, Use Cases and Risk Management*.

European Securities and Markets Authority. 2026a. *AI Adoption and Trends in Securities Markets: EU Evidence*. ESMA TRV Risk Analysis.

European Securities and Markets Authority. 2026b. *Guidelines on Liquidity Management Tools (LMTs) of UCITS and Open-Ended AIFs*. ESMA34-671404336-1364.

European Systemic Risk Board. 2026. *Addressing Frontier AI Models with Cyber Capabilities from a Financial Stability Perspective*.

Forbes (Shrivastava, Rashi, ed.). 2026. "Forbes 2026 AI 50 List."

Hrvatska agencija za nadzor financijskih usluga. 2026. "Zaraza ili međuovisnost? Što povezuje hrvatsko i svjetska tržišta kapitala?" U *Financijska stabilnost*, br. 5.

International Monetary Fund. 2026. "Global Financial Markets Confront the War in the Middle East and Amplification Risks." Chapter 1 in *Global Financial Stability Report*, April 2026.

POPIS KRATICA

AI - umjetna inteligencija (engl. *Artificial Intelligence*)

AIF - alternativni investicijski fond

APP - Program kupnje vrijednosnih papira (engl. *Asset Purchase Programme*)

ATC – Savjetodavni znanstveni odbor (engl. *Advisory Scientific Committee)*

b.b. – bazni bod

BDP – bruto domaći proizvod

CAPE - Ciklički prilagođen omjer cijena i zarada (engl. *cyclically adjusted price-to-earnings ratio)*

DORA – Uredba o digitalnoj otpornosti

DZS – Državni zavod za statistiku

EBA - Europsko nadzorno tijelo za bankarstvo

EIOPA - Europsko nadzorno tijelo za osiguranje i strukovno mirovinsko osiguranje (engl. *European Insurance and Occupational Pensions Authority*)

E3CI – Klimatski indeks europskih ekstremnih događaja (engl. *European Extreme Events Climate Index*)

ESB – Europska središnja banka

ESG – ekološki, društveni i upravljački (engl. *Environmental, Social and Governance*)

ESMA - Europsko nadzorno tijelo za vrijednosne papire i tržišta kapitala (engl. *European Securities and Markets Authority*)

ESRB - Europski odbor za sistemske rizike (engl. *European Systemic Risk Board*)

EU – Europska unija

EUR – euro

FAIM - Napredni modeli umjetne inteligencije (engl. *Frontier AI Models*)

Fed – Sustav federalne rezerve

Hanfa – Hrvatska agencija za nadzor financijskih usluga

HICP – Harmonizirani indeks potrošačkih cijena (engl. *Harmonised Index of Consumer Prices*)

HNB – Hrvatska narodna banka

HZZ – Hrvatski zavod za zapošljavanje

IKT - Informacijska i komunikacijska tehnologija

IPO – Inicijalna javna ponuda (engl. *Initial Public Offering*)

LLM - Veliki jezični modeli (engl. *Large Language Models*)

MF – mirovinski fondovi

mil. – milijun

mlrd. – milijarda

MMF – Međunarodni monetarni fond

M7 - Veličanstvenih 7 (engl. *Magnificent 7*)

p.b. – postotni bod

PDV – porez na dodanu vrijednost

PEPP - hitni program kupnje zbog pandemije (engl. *Pandemic Emergency Purchase Programme*)

ROAA - Povrat na prosječnu imovinu (engl. *Return on Average Assets*)

SCR – potrebni solventni kapital (engl. *Solvency Capital Requirement*)

SIE – Srednja i Istočna Europa

SPO – Sekundarna javna ponuda (engl. *Secondary Public Offering*)

TILDA - tržišni indeks likvidnosti dionica

UCITS – otvoreni investicijski fondovi s javnom ponudom (engl. *Undertakings for Collective Investment in Transferable Securities*)

USD – američki dolar

VIX – indeks volatilnosti (engl. *Volatility Index*)

VSTOXX – indeks volatilnosti EURO STOXX 50 indeksa

ZSE – Zagrebačka burza

Oznake zemalja: AT – Austrija; BE – Belgija; BG – Bugarska; CY – Cipar; CZ – Češka; DE – Njemačka; DK - Danska; EE – Estonija; EL – Grčka; ES – Španjolska; FI – Finska; FR – Francuska; HR – Hrvatska; HU – Mađarska; IE – Irska; IT– Italija; LT – Litva; LV – Latvija; MT – Malta; NL – Nizozemska; PT – Portugal; PL – Poljska; RO – Rumunjska; SAD – Sjedinjene Američke Države; SE – Švedska; SI – Slovenija; SK – Slovačka


HANFA