

Informativna vrijednost tehničkih indikatora u predviđanju kotacijskih cijena državne obveznice: pristup strojnim učenjem

Tea Kalinić Milićević

Ekonomski fakultet, Sveučilište u Splitu

Sažetak

U kontekstu rastuće elektronifikacije i transparentnosti na sekundarnom tržištu državnih obveznica euro zone, ovo istraživanje ispituje informativnu vrijednost tehničkih indikatora u predviđanju unutar dnevnih kotacijskih cijena desetogodišnje njemačke državne obveznice. Pomoću jednosmjerne neuronske mreže na temelju 13 skupova ulaznih podataka i dva izlazna podatka cilj rada je identificirati tehničke indikatore koji najviše pridonose prediktivnoj točnosti i efikasnosti modela u uvjetima manje volatilnog tržišta. Rezultati pokazuju da indikatori trenda, poput MACD (engl. moving average convergence/divergence) i WMA (engl. weighted moving average), te RSI (engl. relative strength index) kao jedini od preostalih promatranih indikatora zamaha omogućuju modelima ostvariti niže prognostičke pogreške od onih postignutih na skupu ulaznih varijabli koji ne uključuje tehničke indikatore. S druge strane, BB (engl. Bollinger bands) kao indikator volatilnosti je rezultirao modelom s najlošijim prediktivnim performansama. Rezultati istraživanja doprinose proširenju primjene tehničke analize izvan tržišta dionica, za koje su primarno bili razvijeni, te omogućuju razvoj efikasnijih modela predviđanja na tržištu državnih obveznica.

Ključne riječi: tehnička analiza; strojno učenje; neuronske mreže; državne obveznice

Vrsta članka: Istraživački članak

Primljeno: 1.8.2025.

Prihvaćeno: 22.9.2025.

DOI: 10.2478/crdj-2025-0012

Uvod

Državne obveznice čine temelj financijskog sustava. Vlade ih koriste za financiranje javne potrošnje, infrastrukturnih projekata i gospodarskih poticaja te kao takve imaju ključnu ulogu u očuvanju gospodarske stabilnosti i podršci financijskoj infrastrukturi. Nadalje, banke ih koriste kao visokokvalitetnu imovinu radi ispunjavanja regulatornih zahtjeva i upravljanja rizicima. Osim toga, zbog niskog rizika u odnosu na druge vrste imovine, one predstavljaju atraktivnu opciju za konzervativne ulagače i institucionalne investitore.

Uvođenjem regulatornih okvira MiFIDII/MiFIR došlo je do značajnog preokreta u načinu trgovanja državnim obveznicama na području euro zone. Navedene reforme potaknule su premještanje dijela trgovanja s nereguliranih OTC (engl. *over-the-counter*) tržišta prema reguliranim platformama za trgovanje (engl. *trading venues*). Paralelno s tim, postupna elektronifikacija tržišta obveznica, kroz sve širu primjenu elektroničkih platformi za trgovanje, dodatno je pridonijela porastu tržišne učinkovitosti. Osim toga, uvođenje strožih zahtjeva o *pre-trade* i *post-trade* izvješćivanju rezultiralo je povećanom transparentnošću trgovanja. Navedeni napredak tržišta obveznica vodio je unaprjeđenju razvoja sekundarnog tržišta državnih obveznica, posebice onog vezanog uz visoko likvidne obveznice.

Prema ICMA (2025) izvješću, tri najlikvidnija izdavatelja državnih obveznica na području euro zone su Italija, Njemačka i Francuska. Među njima se posebno ističu njemačke državne obveznice, kao instrumenti izdavatelja s najvišim kreditnim rejtingom (AAA). Zbog visokog kreditnog rejtinga i niskog rizika povezanog s istim, njemačke državne obveznice imaju referentnu ulogu u procjeni rizika. Koriste se za vrednovanje instrumenata sličnog roka dospijeaća, osobito onih čiji izdavatelji imaju niži kreditni rejting. Osim toga, prinosi na te obveznice se koriste kao temelj za procjenu tržišnih očekivanja. Među njemačkim državnim obveznicama, posebno mjesto zauzimaju one obveznice s vremenom dospijeaća od 10 godina, koje predstavljaju ravnotežu između kratkoročnih i dugoročnih obveznica te se prinos na te obveznice često prati kao signal smjera gospodarskih kretanja te odražava tržišna očekivanja o makroekonomskoj stabilnosti. Sve navedene karakteristike čine njemačke desetogodišnje državne obveznice relevantnim objektom znanstvenog istraživanja. Osim toga, prethodno navedeni razvoj sekundarnog tržišta u pogledu elektronifikacije i transparentnosti, koje za posljedicu imaju povećanu učinkovitost sekundarnog tržišta, otvara prostor za istraživanje tržišne likvidnosti odabranih obveznica i to u pogledu kotacijskih cijena koje određuju širinu kotacijskog kanala poznatog kao široko korišteni indikator nelikvidnosti i to u troškovnoj dimenziji likvidnosti. Istraživanje likvidnosti obveznica, osobito primjenom suvremenih metoda strojnog učenja, postaje prisutno u recentnoj znanstvenoj literaturi (Muller i sur., 2023; Cabrol i sur., 2024) te predstavlja suvremeni pristup analizi tog segmenta financijskog tržišta.

Općenito, analiza financijskih tržišta se temelji na trima glavnim kategorijama analitičkih metodama: tehničkoj analizi, fundamentalnoj analizi te kvantitativnoj analizi. Fundamentalna analiza proučava koji ekonomski čimbenici utječu na tržišne trendove

(Cavalcante i sur., 2016), dok tehnička analiza analizira obrasce kretanja cijena i koristi te obrasce za predviđanje budućih kretanja cijena (Borovkova i Tsiamas, 2019). Unutar tehničke analize, u svrhu proučavanja tržišta te s ciljem boljeg razumijevanja obrazaca cijena, uvedeni su tehnički indikatori (engl. *technical indicators*, TI). Tehnički indikatori definirani su matematičkim formulama temeljenima na povijesnim cijenama ili volumenu trgovanja vrijednosnica te se primjenom heurističkih pravila unutar tehničke analize mogu koristiti za generiranje signala za kupnju (engl. *bullish signals*) ili signala za prodaju (engl. *bearish signals*) (Pricope, 2021). Osim tehničke i fundamentalne analize, temeljnu važnost u analizi financijskih tržišta ima kvantitativna analiza koja predstavlja cjelovitiji pristup analizi tržišta. Ona obuhvaća širok spektar metoda od osnovne deskriptivne statistike i statističkih testova, preko optimizacijskih i simulacijskih postupaka, pa sve do analize vremenskih nizova te naprednih ekonometrijskih metoda i metoda strojnog učenja. Za razliku od fundamentalne analize koja se primarno bavi ekonomskim pokazateljima, te tehničkih indikatora koji opisuju pojedinačne aspekte kretanja cijena, kvantitativne metode, poput metoda strojnog učenja, mogu istovremeno integrirati informacije iz više pokazatelja, od povijesnih cijena, ekonomskih pokazatelja pa i različitih tehničkih indikatora, identificirati složene odnose među njima te koristiti uočene obrasce za predviđanje budućih kretanja na financijskim tržištima.

Temeljem navedenog, ovaj rad povezuje kvantitativnu i tehničku analizu s ciljem ispitivanja značajnosti utjecaja pojedinih tehničkih indikatora na poboljšanje prediktivne točnosti modela strojnog učenja, primijenjenih na predviđanje unutar dnevnih kotacijskih cijena desetogodišnje njemačke državne obveznice. Iako su se tehnički indikatori desetljećima koristili za razvijanje jednostavnih strategija trgovanja (Jiang, 2021), posebice na tržištu dionica za koje su primarno i razvijeni, zbog nedostatka čvrstog teorijskog uporišta i slabe prilagodbe na strukturne promjene na financijskim tržištima, njihova je vrijednost u oblikovanju takvih strategija često dovođena u pitanje. Ipak, s druge strane, ističe se njihova informativna vrijednost u funkciji ulaznih varijabli korištenih prilikom predviđanja cijena na financijskim tržištima primjenom metoda strojnog učenja. Naime, brojna dosadašnja istraživanja koja proučavaju korištenje metoda strojnog učenja za predviđanje cijena na financijskim tržištima, a posebice cijena dionica, u skup ulaznih varijabli uključuju tehničke indikatore.

Kumbure i sur. (2022) u svom pregledu literature o primjeni algoritama strojnog učenja za predviđanje kretanja cijena na burzi, koji obuhvaća 138 znanstvenih članaka objavljenih između 2000. i 2019. godina, ističu da od 2173 identificiranih jedinstvenih varijabli korištenih u navedenim radovima, 1348 (62%) ih pripada kategoriji tehničkih indikatora. Dodatno, Jiang (2021) je proveo pregled literature s fokusom na primjenu metoda dubokog učenja (engl. *deep learning*, DL) za predviđanje kretanja cijena dionica, te je od 124 analizirana znanstvena članka, 46 ih je uključivalo tehničke indikatore kao dio skupa ulaznih varijabli. Osim toga, zajednička upotreba povijesnih cijena i tehničkih indikatora zastupljena je u 25% analiziranih članak. Raniji pregledi literature provedeni od Bustos i sur. (2020) te Henrique i sur. (2019) također ističu tehničke indikatore kao najčešći tip varijabli korištenih kao ulazne varijable u modele strojnog učenja. Osim

toga, većina radova koristi kombinaciju više tehničkih indikatora za predviđanje kretanja tržišta, što upućuje na to da se različiti indikatori mogu međusobno nadopunjavati i time pridonijeti većoj točnosti predviđanja budućih cijena dionica (Kumbure i sur., 2022; Jiang, 2021; Henrique i sur., 2019; Bustos i Pomares-Quimbaya, 2020).

Dok navedeni pregledi literature upućuju na visoku istraženost primjene tehničkih indikatora na tržištu dionica, njihova primjena na tržištu obveznica je znatno manje zastupljena. Navedeno se može, barem djelomično, objasniti značajno manjim brojem istraživanja koji uključuju primjenu metoda strojnog učenja na tržište obveznica, u usporedbi s brojem sličnih istraživanja usmjerenih na tržište dionica. Među istraživanjima o primjeni metoda strojnog učenja u kontekstu tržišta obveznica, Nunes i sur. (2018) koriste pomične prosjeke (engl. *moving averages*, MAs) prinosa do dospelja na 2-, 5-, 10- i 30-godišnje obveznice, uz različite vrijednosti kliznih prozora (engl. *rolling windows*), s ciljem predviđanja krivulje prinosa. Slično, Müller i sur. (2023) koriste pomični prosjek nelikvidnosti kao dio skupa nezavisnih varijabli za predviđanje očekivane nelikvidnosti američkih korporativnih obveznica. Dodatno, Kalinić Milićević (2025) u svom istraživanju pokazuje statistički značajno prediktivnu superiornost modela strojnog učenja, za modeliranje unutardnevnih kotacijskih cijena državne obveznice, temeljenih na skupu ulaznih varijabli koji uključuje tehničke indikatore.

Ovaj rad proširuje istraživanje od Kalinić Milićević (2025) analizom pojedinačnog utjecaja promatranih tehničkih indikatora na prediktivnu točnost modela strojnog učenja temeljenog na jednosmjernoj neuronskoj mreži, koji se u navedenom istraživanju pokazao kao algoritam s najnižom prognostičkom pogreškom. Cilj ovog istraživanja je identifikacija najinformativnijih tehničkih indikatora, koji su izvorno razvijeni za tržište dionica, a u ovom radu se analiziraju u kontekstu tržišta obveznica, i to s primjenom na predviđanje unutardnevne cijene kupnje (engl. *bid price*, *BID*) i cijene prodaje (engl. *ask price*, *ASK*) referentne njemačke državne obveznice. S obzirom na različite karakteristike tržišta dionica i tržišta državnih obveznica, primjerice u pogledu volatilnosti, postavlja se pitanje o vrijednosti pojedinih tehničkih indikatora na manje volatilnom tržištu kao što je ono državnih obveznica, unatoč njihovoj popularnosti u istraživanjima vezanim uz volatilnije tržište dionica. Svrha istraživanja je identificirati dominantne tehničke indikatore u promatranom kontekstu tržišta državnih obveznica te time pridonijeti učinkovitijem rješavanju problema visoke dimenzionalnosti u modelima strojnog učenja, koji može imati negativni učinak na točnost i generalizaciju prediktivnih modela, osobito kod ograničenog broja promatranja, kao što je slučaj kod novoizdanih državnih obveznica. Dakle, istraživanje doprinosi razumijevanju informacijske vrijednosti tehničkih indikatora na tržištu obveznica, području koje je znatno manje istraženo u tom kontekstu, te time i razvoju učinkovitijih modela s kraćim vremenom treniranja.

Razvoj učinkovitog modela strojnog učenja za predviđanje unutardnevnih kotacijskih cijena, pa samim time i širine kotacijskog kanala, pružio bi širokom spektru tržišnih sudionika korisne i pravovremene informacije za donošenje i unaprjeđenje trgovinskih odluka. Tržišnim tvorcima (engl. *market makers*) takav bi model pridonio donošenju odluka o određivanju trenutka i razine prilagodbe svojih kotacija s ciljem održanja

konkurentne cijene tijekom stabilnih razdoblja tržišta kao i zaštite od potencijalnih gubitaka u periodu povećane volatilnosti tržišta. Prilagodnom svojih strategija kotiranja tržišnoj dinamici, tržišni tvorci mogu smanjiti izloženost nepovoljnoj selekciji, povećati profitabilnost i održati stabilnu tržišnu prisutnost, čime potencijalno pridonose poboljšanoj tržišnoj likvidnosti i učinkovitosti formiranja cijena.

Nadalje, precizno unutarдневно predviđanje kotacijskih cijena moglo bi donijeti koristi i institucionalnim investitorima kao i malim ulagačima. Za institucionalne investitore, koji često upravljaju transakcijama velikih volumena koje mogu utjecati na tržišne cijene i pri tome imaju poteškoća pri pronalasku suprotne strane za trgovanje velikim količinama, točno predviđanje kotacijskih cijena bi im omogućilo identifikaciju optimalnih vremenskih intervala tijekom dana u kojima su širine kotacijskih kanala manje, a volatilnost cijene niža. To bi im omogućilo da naloge izvršavaju postupno, kroz manje dijelove, uz izbjegavanje izvršenja naloga u nepovoljnim tržišnim uvjetima te ne utječući na tržišne cijene. S druge strane, mali ulagači, iako trguju znatno manjim volumenima, navedena predviđanja bi mogli koristiti za poboljšanje kratkoročnih trgovinskih odluka.

Istraživanje provedeno u radu podijeljeno je u šest poglavlja. Nakon Uvoda slijedi poglavlje Tehnička analiza u kojem su prezentirani tehnički indikatori korišteni u istraživanju. Nakon poglavlja tehničke analize slijedi poglavlje Metodologija u kojem su opisani podaci i korištena metodologija. Nakon toga slijede Rezultati istraživanja i poglavlje Diskusija unutar kojih su prezentirani i analizirani rezultati. Posljednje je poglavlje Zaključak u kojem su sumirani rezultati te dane preporuke za daljnja istraživanja.

Tehnička analiza

Tehnička analiza (engl. *technical analysis*, TA) je proces analiziranja povijesnih cijena vrijednosnog papira s ciljem određivanja vjerojatnih budućih cijena. Tehnički analitičari koriste tehničke indikatore i analizu svijećnjaka (engl. *candlestick pattern analysis*) kako bi unaprijedili predviđanje kretanja cijena. U skladu s time, brojni znanstveni radovi koriste OHLC (engl. *open, high, low, close*) cijene, volumen trgovanja te tehničke indikatore kao ulazne varijable u modele predviđanja. Pritom se metode korištene za razvoj modela razlikuju ovisno o pristupu unutar tehničke analize: dok se u istraživanjima koja se oslanjaju na tehničke indikatore najčešće primjenjuju regresijske metode, analize obrazaca svijećnjaka temelje se na tehnikama obrade slike (Li i Bastos, 2020). U ovom radu, koristit će se prvi od dva navedena pristupa, unutar kojeg se tehnički indikatori koriste kao ulazne varijable u regresijski model strojnog učenje.

Kako bi se dobio uvid u raznolikost tehničkih indikatora razvijenih unutar tehničke analize, Peng i sur. (2021) predstavili su sveobuhvatan pregled 124 indikatora tehničke analize korištenih u znanstvenoj literaturi objavljenom u razdoblju od 1999. do 2018. godine, kao i onih koje primjenjuju tržišni praktičari. Ipak, unatoč velikom broju postojećih tehničkih indikatora, prema pregledima literature koje su proveli Kumbure i sur. (2022), Peng i sur. (2021) te Bustos i Pomares-Quimbaya (2020), pojedini indikatori

ističu se učestalom primjenom u dosadašnjim istraživanjima. Prema Kalinić Milićević (2025) to su: SMA (engl. *simple moving average*), EMA (engl. *exponential moving average*), WMA (engl. *weighted moving average*), MACD (engl. *moving average convergence/divergence*), RSI (engl. *relative strength index*), stohastički oscilator %D, stohastički oscilator %K, momentum, Williamov %R, CCI (engl. *commodity channel index*), BIAS, BB (engl. *Bollinger bands*), A/D oscilator (engl. *accumulation/distribution oscillator*). Dodatno, navedeni indikatori, osim EMA, BIAS, BB su i sadržani u popularno korištenom skupu tehničkih indikatora predstavljenog u radu od Kara i sur. (2011). Temeljem navedenoga, u nastavku su teorijski predstavljeni tehnički indikatori korišteni u ovom istraživanju, a koji su preuzeti iz istraživanju provedenog u Kalinić Milićević (2025). Nadalje, s obzirom na to da se tehnički indikatori općenito mogu klasificirati u četiri osnovne kategorije, odabrani indikatori su prikazani unutar pripadajućih kategorija.

Indikatori trenda

Trend je primarni element razmatranja u tehničkoj analizi (Colby, 2003). Indikatori trenda (engl. *trend indicators*) ukazuju na smjer promjene cijene promatrane vrijednosnice. Jedni od poznatih indikatora trenda su pomični prosjeci i MACD. Unatoč tome što postoji više različitih vrsta pomičnog prosjeka (Jansen, 2020), tri najkorištenije formulacije su SMA, EMA i WMA, pri čemu će se u ovom radu koristiti WMA.

WMA predstavlja prosjek cijena iz prethodnih n razdoblja, pri čemu su cijenama dodijeljene težine koje odgovaraju indeksima unutar n razdoblja (Jansen, 2020). Formalno, WMA u trenutku t , definira se sljedećom formulom:

$$WMA(n)_t = \frac{2}{n(n+1)} \sum_{i=1}^n i \cdot P_{t-n+i}, \quad (1)$$

gdje su P_{t-n+i} cijene unutar n perioda koji prethodne trenutku t . Ovako definiran pomični prosjek dodjeljuje veće težine novijim podacima te manju važnost starijim podacima.

Sljedeći indikator trenda je MACD koji pokazuje odnos između dva pomična prosjeka cijena promatrane vrijednosnice (Jansen, 2020; Colak i Koy, 2023). MACD se definira kao razlika između kratkoročnog eksponencijalnog pomičnog prosjeka (EMA) i dugoročnog eksponencijalnog prosjeka. Za broj perioda unutar izračuna kratkoročnog i dugoročnog pomičnog prosjeka obično se uzima redom 12 i 26 prethodnih perioda (Colby, 2003).

MACD indikator se sastoji od sljedeće dvije komponente:

1. MACD linije koja predstavlja razliku između brzog i sporog eksponencijalnog pomičnog prosjeka:

$$MACD_t = EMA(n1)_t - EMA(n2)_t, n2 > n1,$$

pri čemu se eksponencijalni pomični prosjek u trenutku t , za broj perioda n , računa po sljedećoj formuli:

$$EMA(n)_t = \alpha P_t + (1 - \alpha)EMA(n)_{t-1},$$

gdje se α obično računa po formuli $\alpha = \frac{2}{n+1}$ (Jansen, 2020; Lokhacheva i sur., 2020; Singh i sur., 2023).

2. Signalne linije koja se definirana kao eksponencijalni pomični prosjek od MACD tijekom 9 prethodnih perioda.

Slijedom navedenog, dva su načina na koji se indikator može koristiti unutar strategije trgovanja: (i) korištenjem temeljne MACD linije ili (ii) promatranjem razlike između MACD i signalne linije. U ovom radu, MACD i signalna linija uključene su kao dvije odvojene ulazne varijable u model strojnog učenja, čime se modelu omogućuje da samostalno uči i procjenjuje odnos između tih komponenti.

Indikatori zamaha

Indikatori zamaha (engl. *momentum indicators*) mjere brzinu kojom se cijena mijenja tijekom vremena. Prema pregledima literature od Kumbure i sur. (2022), Peng i sur. (2021) te Bustos i Pomares-Quimbaya (2020) tehnički indikatori iz ove kategorije su najkorišteniji indikatori u dosadašnjim istraživanjima na tržištu dionica. Među indikatorima ove kategorije ističu se RSI, stohastički oscilatori %D i %K, momentum, Williamov %R indikator te CCI.

Jedan od najpoznatijih indikatora zamaha je RSI indikator (Colby, 2003). RSI indikator se temelji na izračunu prosječnih dobitaka i prosječnih gubitaka u određenom vremenskom razdoblju, pri čemu više vrijednosti indikatora (obično veće od 70) ukazuju da je promatrana vrijednosnica precijenjena dok niže vrijednosti (obično niže od 30) ukazuju na podcijenjenost promatrane vrijednosnice. RSI se definira sljedećom formulom:

$$RSI_t = 100 - \frac{100}{1 + \frac{EMA(n)_{DM^+}}{EMA(n)_{DM^-}}} \quad (2)$$

gdje su DM^+ i DM^- dobitci i gubitci definirani s $DM^+ = \max\{P_t - P_{t-1}, 0\}$, $DM^- = \min\{P_t - P_{t-1}, 0\}$ te $EMA(n)_{DM^+}$, $EMA(n)_{DM^-}$ pripadajući eksponencijalni pomični prosjeci tijekom n perioda. Veći broj perioda n indikator čini manje osjetljivim na promjene cijene dok ga niže vrijednosti broja perioda čine više osjetljivim. Zadana i često korištena vrijednost za n je 14 (Colby, 2003).

Sljedeći indikator zamaha je stohastički oscilator koji uspoređuje cijenu vrijednosnice s rasponom njenih cijena u odabranom razdoblju. Oscilator se sastoji od dvije linije %K i %D koje u postojećoj literaturi nisu nužno korištene jedna s drugom. Obje linije su izvedene iz vrijednosti K koja indicira poziciju trenutne cijene u odnosu na najvišu i najnižu cijenu u promatranom razdoblju. Formalno, za odabranu duljinu razdoblja n , vrijednost K u trenutnu t se računa po sljedećoj formuli:

$$K(n)_t = 100 \cdot \frac{P_t - L_n}{H_n - L_n}, \quad (3)$$

pri čemu je P_t cijena u trenutku t a $L_n = \min\{P_{low,t-n}, \dots, P_{low,t}\}$ i $H_n = \max\{P_{high,t-n}, \dots, P_{high,t}\}$ su najniža i najviša cijena unutar prethodnih n razdoblja. Za broj razdoblja n se često koristi vrijednost 14. Iz izračunatih vrijednosti K , vrijednost %K u trenutku t se dobiva izračunom jednostavnog pomičnog prosjeka od vrijednosti K tijekom prethodna 3 razdoblja, dok se vrijednost %D u trenutku t dobiva izračunom jednostavnog pomičnog prosjeka od %K također tijekom prethodna tri razdoblja. Nakon izračuna linija %K i %D, vrijednost K se izostavlja iz daljnje analize.

Sljedeći indikator unutar ove kategorije je indikator zamaha (engl. momentum), koji nosi istoimeni naziv kao i trenutna kategorija indikatora. Navedeni indikator mjeri količinu promjene cijene unutar promatranog razdoblja (Achelis, 2014). Indikator može biti definiran u obliku razlike ili u obliku omjera, pri čemu je drugi način češće korišten kako bi njegove vrijednosti bile usporedive kroz vrijeme (Colby, 2003). Indikator zamaha u trenutku t se računa po sljedećoj formuli:

$$Mom(n)_t = \frac{P_t}{P_{t-n}} \cdot 100, \quad (4)$$

gdje je P_t cijena vrijednosnice u trenutku t , a P_{t-n} cijena vrijednosnice n razdoblja prije trenutka t . Indikator zamaha pomaže u predviđanju promjene trenda prije nego što do nje dođe, čime predstavlja važan alat unutar tehničke analize (Colby, 2003). Kada cijene na tržištu počnu rasti vrijednost indikatora je obično visoka, ali njezin rast obično usporava kako tržište postaje precijenjeno i interes kupaca slabi ukazujući da trend gubi na snazi, čak i ako cijene i dalje rastu. Slično se događa i u periodu padajućih cijena; indikator postaje manje negativan prije nego što cijena prestane padati, ukazujući na smanjenje pritiska prodaje.

Sljedeći indikator zamaha je Williamov %R, poznat kao Williamov postotni raspon. Indikator je sličan vrijednosti K u stohastičnom oscilatoru, pri čemu je u njegovom slučaju izostavljeno zaglađivanje jednostavnim pomičnim prosjekom, prisutno kod izračuna linija %K i %D. Formula za izračun vrijednosti indikatora u trenutku t dana je s:

$$R(n)_t = \frac{P_n^{high} - P_t}{P_n^{high} - P_n^{low}}, \quad (5)$$

gdje je P_t cijena vrijednosnice u istaknutom trenutku t , dok su $P_n^{high} = \max\{P_{t-n}, \dots, P_t\}$ i $P_n^{low} = \min\{P_{t-n}, \dots, P_t\}$ najviša i najniža cijena unutar razdoblja duljine n . Zanimljivost kod indikatora je njegova sposobnost predviđanja promjene trenda. Naime, indikator doseže lokalni maksimum (minimum) i potom počinje padati (rasti) nekoliko perioda prije nego ista se ista promjena dogodi s cijenom vrijednosnice (Achelis, 2014).

Posljednji indikator u kategoriji indikatora zamaha, obuhvaćen ovim radom je CCI. Indikator CCI mjeri razliku između trenutačne tipične cijene, izračunate kao prosjek trenutačne najniže, najviše te cijene zatvaranja, i povijesnog prosjeka cijene (Colby, 2003, Jansen, 2020). Vrijednost indikatora u trenutku t računa se po sljedećoj formuli:

$$CCI_t = \frac{\bar{P}_t - SMA(n)_t}{0.015 \sum_{t=i}^T |\bar{P}_t - SMA(n)_t| / T} \quad (6)$$

gdje je \bar{P}_t tipična cijena vrijednosnice u trenutku t , n je broj perioda a T je promatrani vremenski period. Vrijednosti indikatora obično variraju između -100% i +100%, pri čemu vrijednosti veće od +100% ukazuju na početak rastućeg trenda, dok vrijednosti ispod -100%, ukazuju na početak novog padajućeg trenda.

Indikator volatilnosti

Indikatori volatilnosti mjere koliko određena varijabla, poput cijene vrijednosnice oscilira tijekom određenog vremenskog perioda. Indikatori volatilnosti, uz indikatore koji se odnose na volumen trgovanja, su kategorije tehničkih indikatora koji su znatno manje zastupljeni u dosadašnjim istraživanjima u odnosu na tehničke indikatore iz prvih dviju kategorija. S obzirom da je tržište obveznica u načelu manje volatilno nego tržište dionica, iz navedene kategorije tehničkih indikatora, istraživanje će uključiti samo jedan tehnički indikator. Prema skupu tehničkih indikatora iz (Kalinić Milićević, 2025), za predstavnika kategorije indikatora volatilnosti izabran je BB.

BB (engl. *Bollinger bands*) indikator analizira udaljenost između trenutačne tipične cijene i prethodnih n tipičnih cijena (Borovkova i Tsiamas, 2019). Indikator je definiran trima linijama: srednja, gornja i donja linija. Srednja linija odgovara jednostavnom pomičnom prosjeku tipičnih cijena tijekom n perioda. Očekuje se da će se cijena vrijednosnice kretati u blizini srednje linije (Nuij i sur., 2014) ali i u granicama drugih dviju linija, gornje i donje linije, koje se temelje na standardnoj devijaciji cijena unutar odabranog perioda n . Kako je standardna devijacija mjera volatilnosti, očekuje se da će se udaljenost granica (engl. *bands*) predstavljenih gornjom i donjom linijom širiti kada je tržište volatilno i sužavati kada se tržište stabilizira (Achelis, 2014). Navedene tri linije se formalno matematički definiraju sljedećim izrazima:

$$Middle_t = SMA(n)_t, \quad (7)$$

$$Upper_t = Middle_t + d\sigma, \quad (8)$$

$$Lower_t = Middle_t - d\sigma, \quad (9)$$

pri čemu je $\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_{t-n+i} - Middle_{t-n+i})^2}$ standardna devijacija tipičnih cijena tijekom n razdoblja a d je broj standardnih devijacija korištenih za definiranje udaljenosti između srednje linije i dviju graničnih linija.

Prethodno predstavljeni tehnički indikatori, pojedinačno će se koristiti kao jedne od ulaznih varijabli u modele strojnog učenja, zajedno s osnovnim dostupnim povijesnim podacima.

U sljedećem poglavlju, opisan je postupak konstrukcije baze podataka korištene u empirijskoj analizi kao i metodološki okvir implementiran u ovom istraživanju.

Metodologija

Podatci

Empirijska analiza ovog istraživanja temelji se na vremenskom nizu povijesnih podataka njemačke državne obveznice sa dospelom od 10 godina. Obveznica je izdana 5. srpnja 2024. godine sa datumom dospelosti od 10 godina. Povijesni niz podataka uključuje podatke na 5-minutnoj frekvenciji unutar trgovinskih dana tijekom prvog mjeseca trgovanja. Preciznije, skup podataka se proteže od 5. srpnja do 31. srpnja 2024. godine pri čemu su za svaki trgovinski dan u promatranom periodu, prikupljeni dostupni povijesni podatci od 9:00 do 17:30 sati s razmakom od 5 minuta, što je rezultiralo s ukupno 1957 prikupljenih zapisa.

Podatci su prikupljeni s Refinitive platforme te uključuju sljedeće ulazne varijable u model: OHLC cijene kupnje, OHLC cijene prodaje, srednju cijenu (engl. *mid price*), prinose povezane s cijenom kupnje, prodaje i srednjom cijenom na kraju svakog petominutnog intervala kao i varijable koje se odnose na broj promjena cijene kupnje i cijene prodaje u svakom petominutnom intervalu. Oznake navedenih varijabli u trenutku $t, t \in \{1, 2, \dots, 1957\}$ su redom: $bid_t^{open}, bid_t^{high}, bid_t^{low}, bid_t^{close}, ask_t^{open}, ask_t^{high}, ask_t^{low}, ask_t^{close}, mid_t, yield_t^{bid}, yield_t^{ask}, yield_t^{mid}, mov_t^{bid}, mov_t^{ask}$.

Za svaki trenutak t definirane su sljedeće dvije ciljane varijable:

$$bid_t = bid_{t+1}^{close}, \quad (10)$$

$$ask_t = ask_{t+1}^{close}. \quad (11)$$

Osim navedenih inicijalnih varijabli, u skup podataka su uključene i varijable s pomakom te varijabla $hour_t$ koja nosi informaciju o satu u danu, kako bi se modelu strojnog učenja pružile dodatne informacije za prepoznavanje obrazaca kroz vrijeme. Detaljnije, za svaku ciljnu varijablu bid_t i ask_t provedbom PAC analize (engl. *partial autocorrelation analysis*) određena su tri vremenska pomaka koja su, na razini značajnosti od 1%, statistički značajno povezana s pripadajućom ciljnom varijablom. Vrijednosti dobivenih pomaka su 38, 76 i 104 dok su pripadajuće varijable označene redom s $bid_t^{38}, bid_t^{76}, bid_t^{104}, ask_t^{38}, ask_t^{76}, ask_t^{104}$.

Izbor navedenih ulaznih varijabli temelji se na kriteriju dostupnosti podataka na unutar-dnevnoj razini. Iako postoje i druge varijable koje potencijalno mogu utjecati na razine kotacijskih cijena, one nisu promjenjive na unutar-dnevnoj razini te stoga nisu uključene u ovo istraživanje. Potencijalno, u skup ulaznih varijabli mogu se uključiti i informacije povezane s makroekonomskim objavama koje su dostupne na unutar-dnevnoj razini, no navedeno se ostavlja kao smjernica za buduća istraživanja.

Konstruirani skup od 21 ulazne varijable se pojedinačno proširio s odabranim tehničkim indikatorima u svrhu konstrukcije skupova za evaluaciju važnosti pojedinog tehničkog indikatora u pridonosenju poboljšanju prediktivne točnosti konstruiranog modela u predviđanju unutar-dnevnih kotacijskih cijena promatrane državne obveznice. U tablici 1 je prikazan popis generiranih skupova pri čemu je u prvom stupcu

naveden naziv skupa dok su u drugom stupcu navedene ulazne varijable uključene u skup zajedno s prethodno navedenim inicijalnim ulaznim varijablama. Treći stupac sadrži vrijednosti postavljenih parametara promatranog tehničkog indikatora. Temeljem analize provedene u (Kalinić Milićević, 2025) koja je rezultirala superiornim performansama modela na skupu ulaznih varijabli koji je sadržavao tehničke indikatora s unaprijed postavljenim, široko korištenim, vrijednostima parametara, u odnosu na modele primijenjene na skup s tehničkim indikatorima s parametrima postavljenima temeljem PAC analize, u ovoj analizi se također promatraju tehnički indikatori s unaprijed postavljenim (tzv. defaultnim) parametrima.

Tablica 1

Skupovi ulaznih varijabli

Naziv skupa	Dodatne ulazne varijable	Postavljeni parametri
wma_38	$WMA_{38}^{bid}, WMA_{38}^{ask}$	$n = 38$
wma_76	$WMA_{76}^{bid}, WMA_{76}^{ask}$	$n = 76$
wma_104	$WMA_{104}^{bid}, WMA_{104}^{ask}$	$n = 104$
wma_38_76_104	$WMA_{38}^{bid}, WMA_{38}^{ask}, WMA_{76}^{bid}, WMA_{76}^{ask}, WMA_{104}^{bid}, WMA_{104}^{ask}$	$n = 38, n = 76, n = 104$
macd	$MACD^{bid}, MACD^{ask}, MACD_{signal}^{bid}, MACD_{signal}^{ask}$	$n_1 = 12,$ $n_2 = 26$
rsi	RSI^{bid}, RSI^{ask}	$n = 14$
stoch d	D^{bid}, D^{ask}	$k = 3$
stoch k	K^{bid}, K^{ask}	$n = 14$
mom	Mom^{bid}, Mom^{ask}	$n = 12$
CCI	CCI^{bid}, CCI^{ask}	$n = 20$
Williams R	R^{bid}, R^{ask}	$n = 14$
BB	$Middle^{bid}, Middle^{ask}, Upper^{bid}, Upper^{ask}, Lower^{bid}, Lower^{ask}$	$n = 20$

Izvor: Izradila autorica

Performanse modela su evaluirane na svakom od skupova predstavljenim u tablici 1 kao i na inicijalnom skupu ulaznih varijabli koji se sastoji od 21 ulazne varijable bez uključenih tehničkih indikatora.

U nastavku rada, prezentiran je metodološki okvir implementiran u istraživanju, koji obuhvaća kratak opis jednosmjernne neuronske mreže kao metode strojnog učenja korištene u istraživanju, te detalje koji se odnose na treniranje i testiranje modela.

Jednosmjerna neuronska mreža

Jednosmjerne neuronske mreže (engl. *feed forward neural networks*, FFNNs) predstavljaju jednu od tri glavne skupine neuronskih mreža, među kojima su još i povratne neuronske mreže (engl. *recurrent neural networks*, RNNs) te konvolucijske neuronske mreže (engl. *convolutional neural networks*, CNNs). Prema Dixon i sur. (2020) neuronske mreže (engl. *neural networks*, NN) se mogu općenito definirati kao nelinearno preslikavanje $F(x)$ u prostoru ulaznih podataka visoke dimenzionalnosti, koje se ostvaruje putem hijerarhijski organiziranih slojeva apstrakcije. Jednosmjerne neuronske mreže se u svojoj arhitekturi sastoje od tri vrste slojeva: ulaznog sloja, skrivenih slojeva te izlaznog sloja. Ukoliko neuronska mreža ima više od jednog skrivenog sloja, onda se ona naziva dubokom neuronskom mrežom (engl. *deep neural network*, DNN).

Proces transformacije ulaznih podataka u izlazni podataka započinje u ulaznom sloju koji prosljeđuje podatke prema skrivenim slojevima, a završava u izlaznom sloju gdje se dobiveni rezultat uspoređuje s očekivanim izlazom ulaznih podataka. Skriveni i izlazni slojevi se sastoje od neurona. Veličina mreže se može opisati njenom dubinom predstavljenom brojem skrivenih slojeva, te njenom širinom predstavljenom brojem neurona u svakom sloju. Neuroni se sastoje od agregacijske i aktivacijske funkcije (Jiang, 2021). Agregacijska funkcija računa linearnu kombinaciju ulaznih podataka određujući težine za svaki od ulaza i uključujući pomak, dok aktivacijska funkcija, ovisno o vrsti, provodi nelinearne transformacije i time omogućuje mreži učenje nelinearnih odnosa. Težine dodijeljene ulaznim podatcima zajedno s pomakom čine parametre neuronske mreže koji se određuju kroz proces treniranja neuronske mreže gdje je cilj optimizirati performanse predviđanja preciznim određivanjem težina. Ažuriranje parametara neuronske mreže tijekom treniranja se provodi pomoću optimizacijskih algoritama koji minimiziraju funkciju troška (engl. *cost function*). Dva popularna optimizacijska algoritma su stohastički gradijentni spust (engl. *stochastic gradient descent*, SGD) i Adam (engl. *adaptive moment estimation*). Funkcija troška obično je povezana s vrstom izlaza, koja je određena vrstom problema strojnog učenja, poput regresije ili klasifikacije. Primjerice, kod regresijskih problema, kao funkcija troška obično se koristi srednja kvadratna pogreška (engl. *mean squared error*, MSE) ili korijen srednje kvadratne pogreške (engl. *root mean squared error*, RMSE).

Dok težine i pomak čine parametre neuronske mreže koji se uče temeljem ulaznih podataka tijekom procesa treniranja neuronskih mreža, broj neurona i skrivenih slojeva, kao i vrsta aktivacijske funkcije i optimizacijskog algoritma čine hiperparametre neuronske mreže koji se mogu nazvati konfiguracijskim postavkama neuronske mreže koje definiraju način treniranja samih mreža. Njihovo precizno postavljanje utječe na konačne prediktivne performanse neuronskih mreža.

Neuronske mreže, pa čak i one jednostavnije kao što su jednosmjerne neuronske mreže, imaju tendenciju predeterminiranosti (engl. *overfitting*) što znači da se parametri mreže previše prilagode podatcima na kojima su mreže trenirane što za posljedicu ima smanjenje mogućnosti generalizacije, odnosno preciznog predviđanja na podatcima za testiranje. Najbolja zaštita od predeterminiranosti je trenirati

neuronsku mrežu na velikoj količini podataka (Jansen, 2020). Kao alternativa ili dodataka tome, mogu se koristiti regularizacijske tehnike kao što su rano zaustavljanje (engl. *early stopping*) ili određivanje stope isključivanja (engl. *dropout rate*). Dok se rano zaustavljanje odnosi na prekidanje procesa treniranja kada se performanse mreže prestanu poboljšavati, postavljanje stope isključivanja podrazumijeva odbacivanje dijela neurona prema određenoj vjerojatnosti. Nasumično isključivanje dijela neurona tijekom propagacije sprječava da se pojedini neuroni previše specijaliziraju za određene obrasce u podacima (James i sur., 2021). Mogućnost ranog zaustavljanja kao i određivanje stope isključivanja predstavljaju još dva hiperparametra neuronske mreže koji se mogu odrediti s ciljem postizanja boljih performansi u predviđanjima na podacima izvan onih na kojima je mreža trenirana.

Odabrani hiperparametri jednosmjerne neuronske mreže, koji uključuju broj neurona, broj skrivenih slojeva, aktivacijsku funkciju, stopu isključivanja, veličinu serije (engl. *batch size*), vrstu optimizacijskog algoritma i stopu učenja unutar njega, su optimizirani primjenom Optuna algoritma (Akiba i sur., 2019) za optimizaciju hiperparametara, individualno za svaki od promatranih skupova ulaznih varijabli. Odabrana složenost procesa optimizacije, koja proizlazi iz broja hiperparametara čije se vrijednosti optimiziraju, opravdana je ciljem postizanja što boljih performansi modela na promatranim skupovima podataka koji bih time omogućili izvođenje relevantnih empirijskih zaključaka. Za svaki od skupova podataka, hiperparametri su optimizirani temeljen evaluacije modela na 300 kombinacija vrijednosti hiperparametara, pri čemu je za treniranje svake kombinacije postavljeno maksimalno 500 epoha. Optimalan broj neurona je određen iz skupa {4,5,6,...,64}, broj skrivenih slojeva iz skupa {1,2,3}, aktivacijska funkcija iz skupa {*ReLU*, *LeakyReLU*, *Tanh*}, veličina serije iz skupa {2,16,32,64}, optimizacijski algoritam iz skupa {*SGD*, *Adam*} te stopa učenja iz segmenta [10^{-5} , 10^{-1}] i stopa isključivanja iz segmenta [0.1, 0.5]. Postupak treniranja i testiranja modela je opisan u sljedećeg potpoglavlju.

Treniranje i testiranje modela

Na svakom od 13 konstruiranih skupova podataka, model temeljen na jednosmjernom neuronskoj mreži je treniran i testiran. U svrhu provođenja evaluacije performansi modela, promatranih skupovi podataka podijeljeni su na tri dijela: skup za treniranje, skup za validaciju i skup za testiranje. Skup za treniranje obuhvaća period od 8.7.2024. do 21.7.2024., skup za validaciju obuhvaća period od 22.7.2024. do 24.7.2024 dok skup za testiranje obuhvaća period od 25.7.2024 do 31.7.2024. Iako inicijalni period promatranja započinje 5.7.2024. (petak), podatci iz tog dana su izostavljeni iz skupa za treniranje jer su se isti koristili pri izračunu varijabli s pomakom i tehničkih indikatora za prvi sljedeći radni dan tj. 8.7.2024. (ponedjeljak). Nadalje, skup za treniranje i skup za validaciju su korišteni za optimizaciju hiperparametara modela, nakon čega je model s rezultirajućim hiperparametrima treniran na periodu od 8.7.2024. do 24.7.2024, te testiran na skupu za testiranje.

Prilikom treniranje modela te optimizacije njihovih hiperparametara, kao mjera točnosti modela korištena je srednja kvadratna pogreška (MSE). Dodatno, u rezultatima

je prikazana i vrijednost koeficijenta determinacije R^2 kao i vrijednost prosječne apsolutne postotne pogreške (engl. *mean absolute percentage error*, MAPE).

Rezultati

Implementacijom prethodno opisanog metodološkog pristupa, modeli temeljeni na jednosmjernoj neuronskoj mreži su trenirani i testirani na ukupno 13 skupova podataka. Prediktivne performanse modela na skupu za treniranje i skupu za testiranje, za svaki od navedenih skupova, prikazane su u tablici 2.

Tablica 2

Rezultati treniranje i testiranja modela temeljenih na FFNN

Skup	Skup za treniranje				Skup za testiranje			
	MSE	R2	MAPE	Rang MSE	MSE	R2	MAPE	Rang MSE
wma_38	0,00154	0,9920	0,0262	5	0,02283	0,8532	0,1167	5
wma_76	0,00158	0,9918	0,0267	8	0,02235	0,8563	0,1163	4
wma_104	0,00141	0,9927	0,0246	1	0,02040	0,8688	0,1099	2
wma_38_76_104	0,00156	0,9920	0,0263	6	0,02381	0,8469	0,1183	7
macd	0,00162	0,9916	0,0274	10	0,02106	0,8646	0,1133	3
rsi	0,00149	0,9923	0,0265	3	0,00506	0,9675	0,0588	1
stoch d	0,00152	0,9921	0,026	4	0,02505	0,8389	0,121	8
stoch k	0,00156	0,9919	0,0258	7	0,02639	0,8303	0,1248	9
mom	0,00175	0,9910	0,0287	12	0,02949	0,8104	0,1335	11
CCI	0,00159	0,9918	0,0269	9	0,03021	0,8057	0,1341	12
Williams R	0,00164	0,9915	0,0272	11	0,02932	0,8115	0,1315	10
BB	0,00184	0,9905	0,029	13	0,04290	0,7241	0,1597	13
Inicijalni (bez TI)	0,00144	0,9926	0,025	2	0,02376	0,8472	0,1189	6

Izvor: Izradila autorica

Prema rezultatima prezentiranim u tablici 2 vidljivo je da modeli temeljeni na samo 5 od ukupno 12 skupova s uključenim tehničkim indikatorima imaju niži MSE na skupu za testiranje od onog postignutog modelom temeljenim na skupa ulaznih varijabli bez tehničkih indikatora. Tehnički indikatori, čije je pojedinačno uključivanje u skup ulaznih varijabli, zajedno s inicijalnim varijabla pridonijelo nižoj prognostičkoj pogrešci pripadajućih modela na skupu za testiranje u odnosu na onu postignutu modelom temeljenim na inicijalnim ulaznim varijablama bez tehničkih indikatora su redom *RSI*, *WMA(104)*, *MACD*, *WMA(76)*, *WMA(38)*. Dodatno, promatrajući rezultate prikazane u tablici 3, može se uočiti da se navedeni tehnički indikatori pokazuju jednako superiornima promatrajući i vrijednosti MSE mjere, pojedinačno za svaku od kotacijskih cijena.

Navedeni rezultati upućuju da se pojedinačno uključivanje promatranih indikatora trenda, koji su najzastupljeniji u istraživanjima na tržištu dionica, pokazalo uspješnim i u kontekstu unutardnevnih predviđanja kotacijskih cijena državne obveznice.

Uključivanje triju pomičnih prosjeka istovremeno, rezultiralo je nešto lošijim performansama modela na skupu za testiranje. Pri tome, može se uočiti da performanse modela na skupu za treniranje kada su uključena tri pomična prosjeka, su bolje nego primjerice kada je uključen pomični prosjek za $n = 76$, dok je odnos performansi istih dvaju modela ali na skupu za testiranje obrnut ukazujući time na predeterminiranost modela temeljenog na podatcima s trima pomičnim prosjecima. Nadalje, iz kategorije indikatora zamaha, samo se RSI istaknuo kao informativno vrijedni indikator u promatranom kontekstu. S druge strane, uključivanje BB kao indikatora volatilnosti rezultiralo je najvećom prognostičkom pogreškom na skupu za testiranje.

Tablica 3

Rezultati testiranja modela, pojedinačno za svaku od kotacijskih cijena

MSE na skupu za testiranje		
Skup	BID	ASK
rsi	0,00489	0,00523
wma_104	0,02001	0,02079
macd	0,02115	0,02096
wma_76	0,02198	0,02272
wma_38	0,02246	0,02319
wma_38_76_104	0,02347	0,02415
stoch d	0,02467	0,02542
stock k	0,02617	0,02662
Williams R	0,02885	0,02978
mom	0,029	0,02999
CCI	0,02993	0,0305
BB	0,04223	0,04356
Inicijalni (bez TI)	0,02333	0,02418

Izvor: Izradila autorica


Kako bih se dobio uvid u prihvatljivost modela, dodatno su dane i vrijednosti MAPE mjere točnosti modela. Promatrajući vrijednosti MAPE mjere, može se uočiti da svi modeli na skupu za treniranje imaju MAPE vrijednosti niže od 10% što ih prema (Lewis, 1982) čini modelima s izrazito točnim predviđanjima na istaknutom skupu. Međutim, promatrajući MAPE vrijednosti na skupu za testiranje, jedino model s rangom 1, ima MAPE niži od 10% i time zadržava status modela s izrazito točnim predviđanjima, sada i na skupu za testiranje. Preostali modeli, promatrajući MAPE vrijednosti koje su više od 10% ali niže od 20%, prema (Lewis, 1982) pripadaju kategoriji niže, tj. smatraju se modelima s dobrim predviđanjima. S obzirom da se prvorangirani model vidno razlikuje od preostalih modela po MAPE mjeri točnosti, zanimljivo je pogledati usporedbu predviđanja navedenog modela i modela s najvišom prognostičkom pogreškom, ali i modela koji ne sadrži tehničke indikatore.

Slijedom navedeno, grafički prikaz odnosa stvarnih vrijednosti ciljnih varijabli na skupu za testiranje i onih predviđenih modelima s najnižom i najvišom prognostičkom

pogreškom, kao i modelom temeljenim na inicijalnom skupu ulaznih varijabli (bez tehničkih indikatora) prikazani su slikama 1-3.

Slika 1

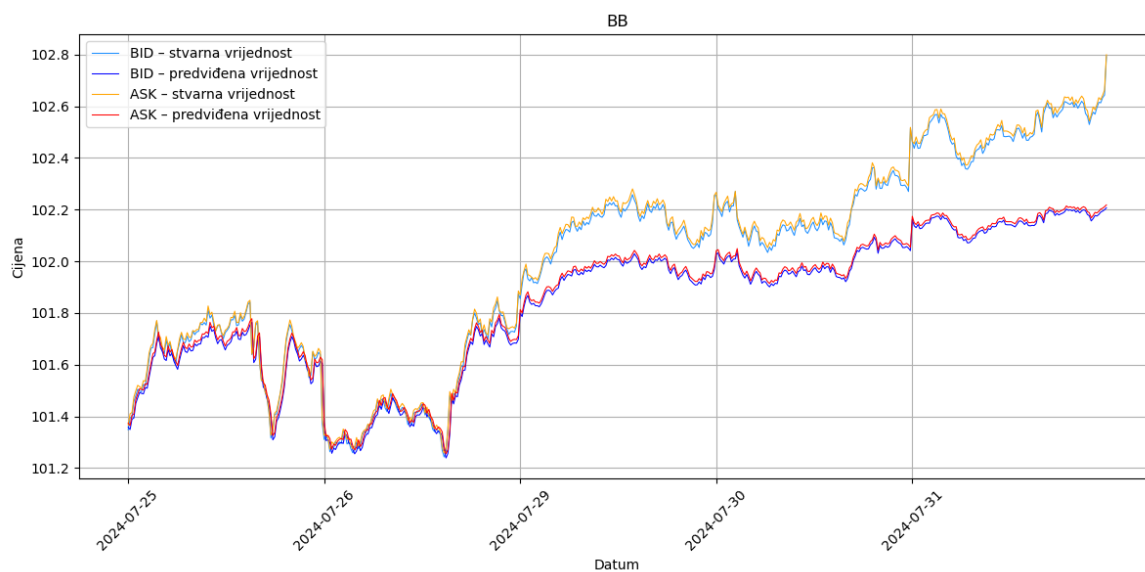
Grafički prikaz cijene kupnje i cijene prodaje previđenih modelom s najnižom prognostičkom pogreškom temeljenim na skupu podataka koji uključuje RSI



Izvor: Ilustracija autorice

Slika 2

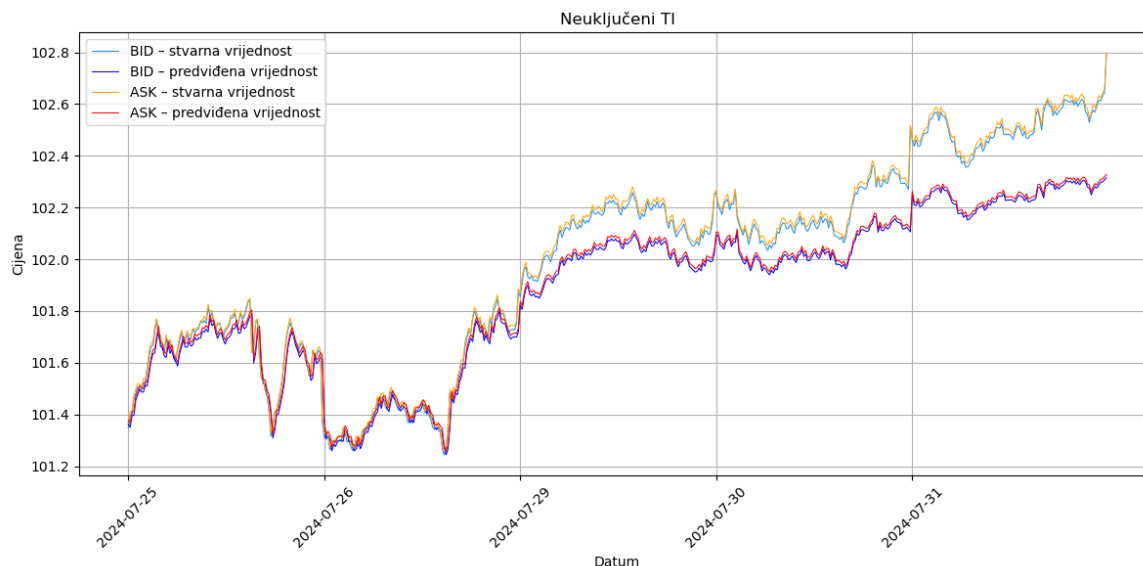
Grafički prikaz cijene kupnje i cijene prodaje previđenih modelom s najvišom prognostičkom pogreškom temeljenim na skupu podataka koji uključuje BB



Izvor: Ilustracija autorice

Slika 3

Grafički prikaz cijene kupnje i cijene prodaje previđenih modelom temeljenim na inicijalnom skupu podataka bez tehničkih indikatora



Izvor: Ilustracija autorice

Iz navedenih grafičkih prikaza može se uočiti da istaknuti modeli imaju slične performanse u početnom dijelu skupa za testiranje, premda čak i u tom dijelu uočavaju se razlike u preciznosti predviđanja sredinom prvog trgovinskog dana (25.7.2025.). Međutim, prediktivni kapaciteti modela u drugom dijelu skupa za testiranje su ono što ističe razliku između performansi promatranih modela. Može se uočiti da model koji je imao pristup vrijednostima tehničkog indikatora RSI ima manje prognostičke pogreške u relativno daljem periodu skupa za testiranje, od modela koji nije imao pristup vrijednostima tehničkih indikatora a posebice od modela koji je imao pristup vrijednosti indikatora volatilnosti. Navedena karakteristika prvorangiranog modela, temeljenog na tehničkom indikatoru RSI, je modelu omogućila i postizanje MAPE vrijednosti niže od 10% te koeficijent determinacije R^2 veći od 0.95, i to uzimajući u obzir cijeli raspon skupa za testiranje. S druge strane, ni jedan od preostalih modela testiranih na jednakom periodu, nije rezultirao MAPE vrijednošću nižom od 10% kao ni vrijednošću od R^2 višom od 0.87.

Slijedom navedenog, može se zaključiti da performanse konstruiranih modela počinju slabiti udaljavanjem novih podataka od perioda na kojem su modeli trenirani, što je zapravo temeljni problem kod predviđanja u kontekstu financijskih tržišta. To je posebno naglašeno kod tržišta državnih obveznica, za koje je karakteristično da se likvidnost obveznica i volatilnost njihovi cijena mijenja kroz život samog financijskog instrumenta tj. period od izdavanja vrijednosnice do dostizanja njenog dospijeca. Posljedično, obrasci koje model nauči na jednom period života obveznice posebice temeljem homogenog skupa varijabli, ne moraju nužno biti primjenjivi i na preostale dijelove. Stoga je često, ovisno o frekvenciji predviđanja, potrebno uključiti i preostale vanjske (makroekonomske i tržišne) i unutarnje (kupone, trajanje, i sl.) faktore koji potencijalno mogu imati utjecaj na tržišno ponašanje obveznice, što predviđanja u

kontekstu obveznica čini znatno izazovnijima u odnosu na predviđanja vezana uz dionica. Što je frekvencija predviđanja niža, to je broj potencijalno utjecajnih varijabli veći, ali je i često veličina skupa podataka ograničena. S druge strane, što je frekvencija predviđanja viša, to se smanjuje dostupnost potencijalno utjecajnih varijabli, ali se povećava veličina raspoloživih podataka. Rezultati analize provedene u ovom radu, temeljene na unutar dnevnom kontekstu, pokazuju da uključivanje tehničkog indikatora RSI je omogućilo modelu najpreciznije predviđanje kotacijskih cijena u sljedećih 515 trenutaka u vremenu, u odnosu na druge modele, što odgovara periodu od 5 trgovinskih dana. Ipak, performanse čak i tog najbolje modela, počinju postajati lošije protekom prvih dvaju trgovinskih dana, što odgovara količini od 206 trenutaka u vremenu. Dakle, može se kazati da u unutar dnevnom kontekstu navedeni model uspijeva obuhvatiti brojčano velik broj trenutaka u vremenu, dok vremenski gledano to odgovara trajanju od 2 trgovinska dana.

Zaključno, indikatori trenda te RSI kao jedan od indikatora zamaha su se pokazali informativno vrijednima u unutar dnevnom predviđanju kotacijskih cijena istaknute njemačke državne obveznice i to na početku njenog trgovanja, kada je dostupnost povijesnih podataka ograničena. S druge strane, promatrajući performanse modela temeljenog na skupu ulaznih podataka s uključenim BB indikatorom, bilo na skupu za treniranje ili na skupu za testiranje, gdje u oba slučaja navedeni model ima najvišu vrijednost ranga koja indicira njegove najmanje kapacitete u ovom problemu predviđanja, može se zaključiti da indikator volatilnosti u ovom kontekstu državnih obveznica nema informativnu vrijednost koja je možebitno zabilježena u istraživanjima vezanim uz tržište dionica, pretpostavljeno temeljem njegove uključenosti u značajan broj istraživanja.

Diskusija

Temeljem provedenog istraživanja i rezultata empirijske analize može se zaključiti da tehnički indikatori koji su se temeljem pregleda literature provedenog od Kumbure i sur. (2022), Peng i sur. (2021) te Bustos i Pomares-Quimbaya (2020) o njihovom frekventnom korištenju u dosadašnjim istraživanjima, pokazali važnima u kontekstu tržišta dionica, u proučavanom kontekstu državnih obveznica nisu svi pokazali jednaku informativnu važnost u predviđanju unutar dnevnih kotacijskih cijena. Naime, BB kao indikator volatilnosti je rezultirao modelom s najnižom prediktivnom preciznošću, ističući smanjenu važnost promatranja volatilnosti u kontekstu sekundarnog tržišta državnih obveznica, posebice na unutar dnevnoj razini, za razliku od njegove potencijalne važnosti na mnogo volatilnijem tržištu dionica. Iz kategorije indikatora zamaha, indikator RSI je pokazao najveću informativnu vrijednost dok momentum, stohastički oscilator D i K, Williamov %R i CCI su rezultirali lošijim performansama modela čak i od modela koji ne uključuje tehničke indikatore. Iz navedenog se može zaključiti da u manje volatilnom kontekstu, omjer prosječnih gubitaka i prosječnih dobitaka nosi vrijedniju informaciju od promatranja pozicioniranosti trenutne cijene u određenom intervalu (kao što je slučaj kod stohastičkih oscilatora i Williamovog %R-a), ili u odnosu na određeni prosjek (kao što je slučaj kod CCI). Dodatno, momentum kao

prilično jednostavan indikator koji uspoređuje trenutnu cijenu s cijenom iz nekog prethodnog perioda, u ovom kontekstu, rezultirao je model pozicioniranim među tri modela s najvećom prognostičkom pogreškom. Konačno, indikatori trenda su se pokazali kao vrijednim tehničkim indikatorima u kontekstu predviđanja kotacijskih cijena, pri čemu je pomični prosjek tijekom 104 perioda, koji odgovaraju jednom trgovinskom danu, superiorni u odnosu na pomične prosjek tijekom kraćeg broja perioda. Time se dodatno ističe važnost duljeg horizonta promatranja s ciljem boljeg zahvaćanja temeljnih stabilnih tržišnih obrazaca karakterističnih za tržište državnih obveznica.

Zaključak

Istraživanje informativne važnosti tehničkih indikatora na tržištu državnih obveznica, u kontekstu unutar dnevnih kotacijskih cijena referentne desetogodišnje njemačke državne obveznice, ističe važnost izbora tehničkih indikatora u promatranom relativnom stabilnom i manje volatilnom tržištu, za razliku od njihove široke upotrebe na više volatilnom tržištu dionica. Dobiveni rezultati opravdavaju prethodno korištenje indikatora trenda u kontekstu tržišta obveznica, pokazujući da indikatori trenda poput MACD i WMA (posebice uz duži period kliznog prozora), imaju informativnu važnost u modelima strojnog učenja, čak i izvan tradicionalnog okvira tržišta dionica. Njihova sposobnost da ublaže potencijalni utjecaj kratkoročnih fluktuacija čini ih pogodnima za predviđanje kotacijskih cijena u stabilnijim tržištima, kao što je sekundarno tržište državnih obveznica.

S druge strane, većina indikatora zamaha pokazala je ograničene informativne mogućnosti u promatranom kontekstu. Jedini indikator iz navedene kategorije indikatora koji je omogućio modelu strojnog učenja ostvariti superiorne performanse u odnosu na sve ostale modele obuhvaćene analizom je RSI. Omjer prosječnih gubitaka i dobitaka praćen indikatorom RSI se, u promatranom kontekstu pokazao informativnijim od ostalih indikatora zamaha koji pozicioniraju trenutnu cijenu unutar intervala ili s obzirom na prosječnu cijenu tijekom nekog perioda. Konačno, BB kao indikator volatilnost, je u kontekstu njemačke državne obveznice pokazao najslabije performanse, što upućuje na njegovu ograničenu primjenjivost u stabilnijem tržišnom okruženju.

Doprinos ovog istraživanja se ogleda upravo u identifikaciji tehničkih indikatora s najvećom informativnom vrijednošću u kontekstu manje volatilnog tržišta državnih obveznica, što omogućuje učinkovitiji odabir ulaznih varijabli, smanjenje dimenzionalnosti te povećanje efikasnosti modela strojnog učenja. Iako se navedenim proširuje primjena tehničke analize izvan tržišta dionica, u budućim istraživanjima bih se trebale istražiti metode za prilagodbu parametara tehničkih indikatora, koji su prvobitno prilagođeni upravo za tržište dionica, s ciljem ekstrakcije što je više moguće vrijednih informacija u svrhu preciznih predviđanje budućih kretanja vrijednosti državnih obveznica. Također, buduća istraživanja bi trebala razmotriti uključivanje informacija i iz drugih faktora, bilo vanjskih ili unutarnjih, poput makroekonomskih obavijesti kao i primjerice informacija vezanih uz vrijeme do sljedećeg kupona,

uzimajući u obzir ograničenja postavljena temeljem dostupljenosti podataka na unutarodnevnoj razini.

Literatura

1. Achelis, S. B. (2014). *Technical analysis from A to Z*. McGraw-Hill.
2. Akiba, T., Sano, S., Yanase, T., Ohta, T., and Koyama, M. (2019). Optuna: A Next-generation Hyperparameter Optimization Framework. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*.
3. Borovkova, S. and Tsiamas, I. (2019). An ensemble of LSTM neural networks for highfrequency stock market classification. *Journal of Forecasting* 38(6), 600–619. doi:10.1002/for.2585.
4. Bustos, O. and Pomares-Quimbaya, A. (2020). Stock market movement forecast: A Systematic review. *Expert Systems with Applications* 156, 113464. doi: 10.1016/j.eswa.2020.113464.
5. Cabrol, A., Drobetz, W., Otto, T., and Puhan, T. (2024). Predicting Corporate Bond Illiquidity via Machine Learning. *Financial Analysts Journal*, 80(3), 103–127. doi: 10.1080/0015198x.2024.2350952.
6. Cavalcante, R. C., Brasileiro, R. C., Souza, V. L., Nobrega, J. P., and Oliveira, A. L. (2016). Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications* 55, 194–211. doi: <https://doi.org/10.1016/j.eswa.2016.02.006>.
7. Colak, A. B. and Koy, A. (2023). The role of technical indicators in the intraday prediction of Stock Markets: Artificial Neural Network models for Borsa Istanbul. *Scientia Iranica*. doi: 10.24200/sci.2023.58490.5752.
8. Colby, R. W. (2003). *The Encyclopedia of Technical Market Indicators*. McGraw-Hill.
9. Henrique, B. M., Sobreiro, V. A., and Kimura, H. (2019). Literature review: Machine learning techniques applied to financial market prediction. *Expert Systems with Applications* 124, 226–251. doi: 10.1016/j.eswa.2019.01.012.
10. ICMA (2025, ožujak). *Secondary Market Practices Committee European Secondary Market Data Report*. The International Capital Market Association. <https://www.icmagroup.org/assets/documents/Regulatory/Secondary-markets/ICMA-Secondary-Market-Practices-Committee-European-Secondary-Market-Data-Report-H2-2024-Sovereign-Edition-March-2025-210325.pdf>
11. Jansen, S. (2020). *Machine Learning for Algorithmic Trading* (2nd ed.). Packt.
12. Jiang, W. (2021). Applications of deep learning in stock market prediction: Recent progress. *Expert Systems with Applications* 184, 115537. doi: 10.1016/j.eswa.2021.115537.
13. Kalinić Milićević, T. (2025). Assessment of bid-ask spread in the bond market with machine learning. Faculty of Economics, Business and Tourism, University of Split.
14. Kumbure, M. M., Lohrmann, C., Luukka, P., and Porras, J. (2022). Machine learning techniques and data for stock market forecasting: A literature review. *Expert Systems with Applications* 197, 116659. doi: 10.1016/j.eswa.2022.116659.

15. Li, A. W. and Bastos, G. S. (2020). Stock market forecasting using Deep Learning and Technical Analysis: A systematic review. *IEEE Access* 8, 185232–185242. doi: 10.1109/access.2020.3030226.
16. Lewis, C. D. (1982). *Industrial and business forecasting methods: A Radical guide to exponential smoothing and curve fitting*. London; Boston: Butterworth Scientific.
17. Lokhacheva, K., Parfenov, D., and Bolodurina, I. (2020). Reinforcement learning approach for market-maker Problem Solution. *Proceedings of the International Session on Factors of Regional Extensive Development (FRED 2019)*. doi: 10.2991/fred-19.2020.52.
18. Müller, M., Reichenbacher, M., Schuster, P., and Uhrig-Homburg, M. (2023). Expected bond liquidity. *SSRN Electronic Journal*. doi: 10.2139/ssrn.3642604.
19. Nuij, W., Milea, V., Hogenboom, F., Frasinca, F., and Kaymak, U. (2014). An automated framework for incorporating news into stock trading strategies. *IEEE Transactions on Knowledge and Data Engineering* 26 (4), 823–835. doi: 10.1109/tkde.2013.133.
20. Nunes, M., Gerding, E., McGroarty, F., and Niranjana, M. (2018). Artificial neural networks in fixed income markets for yield curve forecasting. *SSRN Electronic Journal*. doi: 10.2139/ssrn.3144622.
21. Peng, Y., Albuquerque, P. H., Kimura, H., and Saavedra, C. A. (2021). Feature selection and deep neural networks for stock price direction forecasting using technical analysis indicators. *Machine Learning with Applications* 5, 100060. doi: 10.1016/j.mlwa.2021.100060.
22. Pricope, T.-V. (2021). Deep Reinforcement Learning in Quantitative Algorithmic Trading: A Review. *arXiv preprint arXiv:2106.00123*. doi: 10.48550/arXiv.2106.00123.
23. Singh, T., Kalra, R., Mishra, S., Satakshi, and Kumar, M. (2023). An efficient real-time stock prediction exploiting incremental learning and Deep Learning. *Evolving Systems* 14(6), 919–937. doi: 10.1007/s12530-022-09481-x.

O autorici

Tea Kalinić Milićević je viša asistentica na Katedri za kvantitativne metode na Ekonomskom fakultetu Sveučilišta u Splitu. Diplomirala je na Prirodoslovno-matematičkom fakultetu u Splitu, smjer Računarska matematika. Završila je poslijediplomski specijalistički studij Poslovne ekonomije na Ekonomskom fakultetu, Sveučilišta u Splitu gdje je i potom doktorirala iz područja kvantitativne ekonomije s doktorskim radom po nazivom „Assessment of bid-ask spread in the bond market with machine learning“. Njezino glavno područje istraživanja usmjereno je na primjene kvantitativnih metoda, posebice metoda strojnog učenja na područje ekonomski znanosti. Do sada je objavila osam znanstvenih radova, jedan stručni rad i jedan sveučilišni udžbenik, te je sudjelovala na sedam međunarodnih znanstvenih skupova. Također, bila je član istraživačke skupine na znanstvenom projektu pod nazivom „Challenges of Alternative Investments“. Autoricu možete kontaktirati na tkalinic@efst.hr.