

SVEUČILIŠTE U RIJECI
GRAĐEVINSKI FAKULTET U RIJECI

Kristina Galjanić

**RAZVOJ MODELA PREDVIĐANJA
PERFORMANSI I ISHODA GRAĐEVINSKIH
PROJEKATA**

DOKTORSKI RAD

Mentor: prof. dr. sc. Ivan Marović, dipl. ing. građ.

Rijeka, 2025.

UNIVERSITY OF RIJEKA
FACULTY OF CIVIL ENGINEERING

Kristina Galjanić

**DEVELOPMENT OF A MODEL FOR PREDICTING
PERFORMANCE AND OUTCOMES OF
CONSTRUCTION PROJECTS**

DOCTORAL THESIS

Rijeka, 2025

Mentor doktorskog rada:

Prof. dr. sc. Ivan Marović, Sveučilište u Rijeci, Građevinski fakultet

Doktorski rad obranjen je dana _____ na Građevinskom fakultetu Sveučilišta u Rijeci.

Povjerenstvo za ocjenu doktorskog rada:

Prof. dr. sc. Aleksandra Deluka-Tibljaš, Sveučilište u Rijeci, Građevinski fakultet

Prof. dr. sc. Mladen Vukomanović, Sveučilište u Zagrebu, Građevinski fakultet

Izv. prof. dr. sc. Katarina Rogulj, Sveučilište u Splitu, Fakultet građevinarstva, arhitekture i geodezije

Zahvala

Iskreno zahvaljujem mentoru, prof. dr. sc. Ivanu Maroviću, na stručnom vodstvu, pristupačnosti, korisnim savjetima i kontinuiranoj motivaciji tijekom cijelog doktorskog studija.

Zahvaljujem članovima Povjerenstva za ocjenu doktorskog rada, prof. dr. sc. Aleksandri Deluka-Tibljaš, prof. dr. sc. Mladenu Vukomanoviću i izv. prof. dr. sc. Katarini Rogulj, na vremenu uloženom u pregled rada, stručnoj analizi i korisnim primjedbama prilikom njegove ocjene. Također, zahvaljujem članovima Povjerenstva za ocjenu teme, prof. dr. sc. Diani Car-Pušić, prof. dr. sc. Mladenu Vukomanoviću i prof. dr. sc. Hrvoju Krstiću na komentarima i smjernicama koji su usmjerili izradu disertacije.

Želim izraziti zahvalnost Upravi GP KRK d.d. na podršci u realizaciji istraživanja te kolegama i kolegicama na suradnji i stručnim razgovorima tijekom izrade ovog rada.

Hvala svim profesorima, profesoricama te kolegama i kolegicama Građevinskog fakulteta u Rijeci na toplim riječima podrške i poticajima, još i prije nego što sam postala dio kolektiva.

Zahvaljujem prof. dr. sc. Urošu Klanšeku na iznimnoj susretljivosti i konstruktivnim savjetima te prof. dr. sc. Tomašu Hanaku, prof. dr. sc. Mariju Galiću i prof. dr. sc. Nikši Jajcu na vrijednim komentarima i potpori tijekom doktorskog studija.

Zahvaljujem svojim dragim prijateljima i prijateljicama koji su ovo razdoblje učinili lakšim i veselijim te bili neprocjenjiv dio ovog putovanja.

Posebno zahvaljujem svojoj obitelji na vjeri, podršci i ljubavi te na stalnom poticaju i povjerenju koje mi daju u svakom koraku prema ostvarenju ciljeva.

SAŽETAK

Disertacija prikazuje razvoj modela predviđanja performansi i ishoda građevinskih projekata primjenjiv u fazi izvođenja radova. Na temelju pregleda literature, polustrukturiranih intervjua i višestruke studije slučaja identificiraju se ključna područja performansi (kvaliteta, vrijeme, trošak, sigurnost, produktivnost, zadovoljstvo sudionika i zadovoljstvo investitora) relevantna za postizanje uspjeha projekta. U okviru teorijskog i empirijskog dijela istraživanja prikupljaju se i obrađuju podatci o 12 građevinskih projekata financiranih javnim sredstvima, s ugovorenim vrijednostima između 7,5 i 25 milijuna eura. Primjenom metoda strojnog učenja, uključujući neuronske mreže i algoritam slučajne šume, razvijaju se modeli predviđanja prekoračenja ugovorenog trajanja i iznosa. Modeli se temelje na ključnim pokazateljima uspješnosti (značajkama) definiranih područja performansi te omogućuju identifikaciju najutjecajnijih značajki, čime se optimizira opseg podataka potrebnih za buduću primjenu. Validacije modela i vizualizacije rezultata potvrđuju njihovu pouzdanost i primjenjivost u stvarnim projektima. Dodatno, razvija se model predviđanja krivulje kumulativnog napretka koji koristi rezultate modela predviđanja prekoračenja ugovorenog trajanja i iznosa. Kombiniranjem tih rezultata s drugim relevantnim ulaznim podacima omogućuje se praćenje dinamike izvođenja u odnosu na planirani tijek projekta. Razvijeni modeli strukturiraju se kao podsustav za upravljanje modelima, predviđen kao dio sustava za podršku odlučivanju. Takav sustav omogućuje ključnim dionicima (investitoru, izvođaču i nadzornom inženjeru) pravovremeno prepoznavanje rizika, unapređuje komunikaciju i potiče ciljane mjere prilagodbe u slučajevima prekoračenja. Primjena na stvarnom projektu pokazuje da modeli omogućuju ranu identifikaciju odstupanja, analizu uzroka i odabir optimalnih mjera prilagodbe. Time se potvrđuje da integracija modela u upravljanje građevinskim projektom može značajno unaprijediti kontrolu nad ostvarenim performansama i osigurati postizanje ciljanih ishoda. Zaključno, razvijeni modeli predviđanja predstavljaju vrijedan alat za proaktivno i dinamično upravljanje građevinskim projektima. Istraživanje nudi sveobuhvatan metodološki okvir za predviđanje performansi i ishoda, uz naglašavanje važnosti višedioničke perspektive, pravovremene komunikacije i kontinuirane evaluacije kao temelja za uspješnu realizaciju građevinskih projekata.

Ključne riječi:

građevinski projekti, upravljanje projektima, model predviđanja, strojno učenje u građevinarstvu, ključna područja performansi, prekoračenje ugovorenog trajanja i iznosa, podsustav za upravljanje modelima, sustavi za podršku odlučivanju, suradnja dionika, krivulja kumulativnog napretka, neuronske mreže

SUMMARY

This dissertation presents the development of a prediction model for the performance and outcomes of construction projects, applicable during the execution phase. Based on a comprehensive literature review, semi-structured interviews, and multiple case studies, key performance areas (quality, time, cost, safety, productivity, stakeholder satisfaction and investor satisfaction) relevant to project success are identified. Within the theoretical and empirical parts of the research, data are collected and analyzed for 12 publicly funded construction projects with contract values ranging from 7.5 to 25 million euros. By applying machine learning methods, including neural networks and random forest algorithm, models are developed to predict schedule and budget overruns. These models rely on quantified indicators of the identified performance areas and enable the identification of the most influential variables, thereby optimizing the scope of data required for future applications. Model validation and result visualization confirm their reliability and applicability in real projects. In addition, a model for predicting the cumulative progress curve is developed, using the outputs of the schedule and budget overrun prediction models. By combining these results with other relevant input data, it becomes possible to monitor actual project progress in relation to the planned project schedule. The developed models are structured as a model management subsystem, envisaged as part of a decision support system. Such a system enables key stakeholders (the client, the contractor and the supervising engineer) to identify risks in a timely manner, enhance communication and encourage targeted corrective actions in cases of deviations. Application on a live project demonstrates that the models enable early deviation detection, causal analysis and the selection of the most appropriate corrective actions. This confirms that integrating the models into construction project management can significantly improve control over achieved performance and ensure the achievement of targeted outcomes. In conclusion, the developed prediction models represent a valuable tool for proactive and dynamic management of construction projects. The research provides a comprehensive methodological framework for predicting project performance and outcomes, highlighting the importance of a multi-stakeholder perspective, timely communication and continuous evaluation as key foundations for successful project delivery.

Keywords:

construction projects, project management, predictive modeling, machine learning in construction, key performance areas, schedule and budget overruns, model management subsystem, decision support systems, stakeholder collaboration, cumulative progress curve, neural networks

Sadržaj

SAŽETAK	
SUMMARY	
1. UVOD.....	1
1.1. Definiranje predmeta istraživanja	1
1.2. Ciljevi i hipoteze istraživanja	4
1.3. Metodologija istraživanja	6
1.4. Struktura disertacije	7
2. PREGLED I ANALIZA DOSADAŠNJIH ISTRAŽIVANJA	10
2.1. Analiza aktualnih istraživačkih trendova	10
2.2. Standardi, metodologije i izazovi u suvremenom upravljanju projektima	17
2.3. Teorija upravljanja dionicima	19
2.3.1. Razvoj teorije upravljanja dionicima	20
2.3.2. Definiranje i identifikacija dionika	21
2.3.3. Upravljanje dionicima u građevinskim projektima	23
2.4. Percepcije uspjeha u građevinskim projektima	25
2.5. Opći pregled ključnih područja performansi	26
2.5.1. Kvaliteta	29
2.5.2. Vrijeme	30
2.5.3. Troškovi	30
2.5.4. Sigurnost	31
2.5.5. Profitabilnost	32
2.5.6. Produktivnost	33
2.5.7. Zadovoljstvo sudionika	34
2.5.8. Zadovoljstvo investitora	35
2.5.9. Zaključno o područjima performansi	35
2.6. Uloga sustava za podršku odlučivanju u upravljanju građevinskim projektima	36
2.6.1. Donošenje odluka i informacijski sustavi za podršku odlučivanju	37
2.6.2. Sustavi za podršku odlučivanju	39
2.7. Umjetna inteligencija, strojno i duboko učenje	41
2.7.1. Uvod u neuronske mreže	42
2.7.2. Arhitektura, parametri i hiperparametri neuronske mreže	43
2.8. Krivulja kumulativnog napretka projekta	46

2.9.	Integracija teorijskih pristupa u kontekstu upravljanja građevinskim projektima	48
3.	METODOLOGIJA I MODELIRANJE	50
3.1.	Razvoj evaluacijskog okvira za predviđanje performansi i ishoda građevinskih projekata	52
3.1.1.	Proces razvoja evaluacijskog okvira	52
3.1.2.	Validacija evaluacijskog okvira kroz višestruku studiju slučaja	54
3.2.	Razvoj modela predviđanja prekoračenja ugovorenog trajanja i iznosa	58
3.2.1.	Prikupljanje i priprema podataka za neuronsku mrežu	60
3.2.2.	Odabir ulaznih podataka za neuronsku mrežu.....	66
3.2.3.	Dodatna optimizacija izabranog modela.....	68
3.3.	Razvoj i odabir modela predviđanja krivulje kumulativnog napretka projekta	69
3.3.1.	Matematički modeli	72
3.3.2.	Proces razvoja modela neuronske mreže	73
3.4.	Evaluacija, vizualizacija i validacija modela	74
3.5.	Primjena modela i adaptivni ciklus.....	77
4.	REZULTATI ISTRAŽIVANJA I RASPRAVA	80
4.1.	Rezultati validacije evaluacijskog okvira za predviđanje performansi i ishoda građevinskih projekata.....	80
4.1.1.	Slučaj A	80
4.1.2.	Slučaj B	81
4.1.3.	Slučaj C	82
4.1.4.	Slučaj D	82
4.1.5.	Slučaj E.....	83
4.1.6.	Zaključci višestruke studije slučaja	84
4.1.7.	Povezivanje evaluacijskog okvira s predviđanjem performansi i ishoda građevinskih projekata.....	88
4.2.	Model predviđanja prekoračenja ugovorenog trajanja	89
4.2.1.	Odabir značajki i inicijalna optimizacija modela predviđanja prekoračenja ugovorenog trajanja	90
4.2.2.	Dodatna optimizacija hiperparametara i analiza performansi modela predviđanja prekoračenja ugovorenog trajanja.....	95
4.2.3.	Unakrsna validacija modela predviđanja prekoračenja ugovorenog trajanja ..	101
4.3.	Model predviđanja prekoračenja ugovorenog iznosa	102

4.3.1.	Odabir značajki i inicijalna optimizacija modela predviđanja prekoračenja ugovorenog iznosa	102
4.3.2.	Dodatna optimizacija hiperparametara i analiza performansi modela predviđanja prekoračenja ugovorenog iznosa	107
4.3.3.	Unakrsna validacija modela predviđanja prekoračenja ugovorenog iznosa.....	113
4.4.	Rasprava o modelima predviđanja prekoračenja ugovorenih trajanja i iznosa	114
4.5.	Model predviđanja krivulje kumulativnog napretka	115
4.5.1.	Matematički modeli predviđanja krivulje kumulativnog napretka	116
4.5.2.	Model neuronske mreže za predviđanje krivulje kumulativnog napretka	119
4.5.3.	Rasprava i odabir optimalnog modela predviđanja krivulje kumulativnog napretka	127
5.	PERSPEKTIVNI DIO	130
5.1.	Primjena razvijenih modela na aktivnom građevinskom projektu	130
5.2.	Identifikacija sličnih tržišta građevinske industrije	136
6.	ZAKLJUČAK	140
6.1.	Znanstveni doprinos istraživanja	142
6.2.	Praktični doprinos istraživanja	144
6.3.	Ograničenja i pravci daljnjih istraživanja	145
	POPIS LITERATURE.....	146
	PRILOZI	165
	POPIS SLIKA	198
	POPIS TABLICA.....	200
	POPIS KRATICA	202
	ŽIVOTOPIS AUTORA.....	203

1. UVOD

1.1. Definiranje predmeta istraživanja

Unatoč inovativnim idejama, znatnom trudu i velikim financijskim ulaganjima, mnogi projekti ne završavaju uspješno. Iako se realiziraju u skladu s tehničkim specifikacijama, njihova ukupna uspješnost često se dovodi u pitanje zbog prekoračenja ugovorenog trajanja i iznosa. Prema izvješću PMI-ja (2021), 73 % projekata uspješno ispunjava svoje izvorne ciljeve i poslovne namjere. Međutim, samo 62 % projekata završava unutar predviđenog proračuna, dok ih 55 % završava u okviru predviđenog vremenskog roka. Premda su građevinski projekti u pravilu temeljito isplanirani, njihova realizacija u stvarnim uvjetima otežana je nizom izazova kao što su vremenska ograničenja, česte izmjene tijekom izvođenja radova te složeni regulatorni zahtjevi. Dodatno otežavajuće okolnosti stvaraju vanjski čimbenici poput vremenskih neprilika i globalnih događanja (inflacija, financijske oscilacije na tržištu, nedostatak kvalificirane radne snage, posljedice nedavne pandemije i slično). Takvo dinamično okruženje zahtjeva kontinuirano prilagođavanje. Ovi podatci ukazuju na značajan prostor za unapređenje upravljanja građevinskim projektima te potvrđuju potrebu za razvojem alata koji omogućuju aktivno utjecanje na ishode i postizanje veće uspješnosti građevinskih projekata.

S obzirom na ove izazove, mnogobrojna istraživanja već godinama nastoje odgovoriti na pitanje što čini uspješan projekt i kako ga ostvariti. Ipak, još uvijek ne postoji jedinstveni dogovor o kriterijima koji su ključni za postizanje uspjeha. Tradicionalni pristupi analizi uspjeha često se oslanjaju na željezni trokut koji analizira cijenu, vrijeme i kvalitetu (Abdulhayoglu i Thijs, 2018). Popularnost pristupa proizlazi iz dobre mjerljivosti kriterija. Ipak, kasnija istraživanja uvelike ga kritiziraju jer su navedeni kriteriji nedostadni za postizanje uspjeha projekta iz šire perspektive (de Wit, 1988). Sukladno tome, postizanje potrebne razine performansi zahtijeva promatranje i drugih aspekata (Toor i Ogunlana, 2010). Chen (2015) ističe ključne kriterije kao što su komunikacija, timski rad, kreativnost, tehnologija, upravljanje rizicima, kvaliteta i materijali. He i dr. (2019) predlažu uključivanje poštivanja rokova, proračuna, ostvarenje planiranih ciljeva te prihvatanje rezultata od strane investitora. Radujković i dr. (2021) nude analizu uspjeha projekta kroz 29 kategorija na makro razini koje obuhvaćaju dionike, rezultate i kriterije povezane s organizacijom projekta i upravljanjem nadopunjujući tradicionalne kriterije (vrijeme, trošak, kvaliteta). Mnogi istraživači su tijekom proteklih godina istraživali i identificirali raznovrsne pristupe, alate i metode za procjenu i mjerenje uspješnosti upravljanja projektima, usredotočujući se na ulazne attribute koji utječu na rezultate projekta (Chen, 2015;

Chen, 2014; Scott-Young i Samson, 2008; Tabassi i Bakar, 2009). Većina tih istraživanja je tradicionalno usmjerena na cjelokupni životni ciklus projekta (Chen, 2014; El-Sayegh, 2008), dok se relativno malo njih usredotočuje na specifičnosti faze izvođenja projekta (Chen, 2015), a posebno na činjenicu da različiti dionici percipiraju uspjeh projekta na različite načine (Montenegro i dr., 2021; Turner i Zolin 2012).

Predložen je niz modela, sustava i okvira za upravljanje performansama. Lin i Shen (2007) ističu da postoji velik broj različitih modela zbog potrebe za praćenjem različitih performansi iz različitih perspektiva. Tvrdi da su multiperspektivni pokazatelji ključni za mjerenje performansi te da bi primjena metodologije uravnoteženih ciljeva (engl. Balance Scorecard, BSC) trebala poboljšati performanse (Bassioni i dr., 2004; Dwivedi i dr., 2021; Vukomanović i Radujković, 2013). Međutim, modeli temeljeni na metodologiji uravnoteženih ciljeva često su kritizirani zbog grupiranja uzroka i posljedica zajedno kao pokazatelja ukupnih performansi (Jonas i dr., 2013; Kostelac i dr., 2016). Stoga su se istraživači usredotočili na razvoj pristupa mjerenja performansi. Chen (2015) za predviđanje neuspjeha projekta po završetku uzima u obzir komunikaciju, tim, kreativnost, tehnologiju, rizik, kvalitetu i materijale. Cha i Kim (2011) predlažu ukupnu ocjenu performansi kao sredstvo kvantificiranja sustava pokazatelja uspješnosti projekta temeljenog na 18 ključnih pokazatelja koji obuhvaćaju osam područja performansi. Leon i dr. (2017) razvijaju pristup dinamike sustava za predviđanje performansi građevinskog projekta. Također, razvijeni su i fragmentirani modeli predviđanja i modeli usmjereni na specifične aspekte performansi kao što su model operativnog istraživanja za predviđanje performansi izvođača (Tam i Harris, 1996), model podrške odlučivanju za upravljanje performansama lanca opskrbe u izgradnji (Yilzid i Ahi, 2020), model upravljanja rizikom na temelju razmatranja troškova i vremenskih planova (Kim, 2010) te metodologija razvoja i primjene registra rizika u građevinskim projektima (Burcar Dunović i dr., 2013).

U skladu s razvojem tehnologije i rastućim zahtjevima za pravovremenim i preciznim predviđanjem, istraživanja se sve više odmiču od tradicionalnih analitičkih pristupa prema digitalnim metodama. U posljednjem desetljeću sve je učestalija primjena metoda mekog računarstva, uključujući umjetne neuronske mreže, genetske algoritme, fuzzy logiku i druge napredne metode (Al Mnaseera i dr., 2023; Coffie i Cudjoe, 2024; Leśniak i Juszczak, 2018; Obianyo i dr., 2022; Petruseva i dr., 2012; Senouci i dr., 2016; Tijanić Štrok i dr., 2019; Trijeti i dr., 2023). Ovi pristupi omogućuju modeliranje složenih nelinearnih odnosa, što klasičnim metodama često izmiče. Ipak, njihova učinkovitost u fazi izvođenja građevinskog projekta i dalje ovisi o ljudskim procjenama, percepcijama i odlukama, što unosi nesigurnost u njihovu primjenu.

Prethodna istraživanja pružaju smjernice za mjerenje performansi projekta, ali ne obuhvaćaju analizu kako pojedina područja performansi utječu na uspjeh projekta iz perspektive različitih dionika. Postojeća istraživanja pokazuju razlike u percepcijama

ključnih pokazatelja uspjeha među dionicima (Radujković i dr., 2021; Toor i Ogunlana, 2010), kao i u shvaćanjima pojedinih atributa koji utječu na financijske performanse (Doloi, 2013; Wawak i dr., 2020). Kao što su istaknuli Ward i Chapman (2008), dionici predstavljaju glavni izvor neizvjesnosti u projektu. Svaki od njih pridonosi svojim individualnim perspektivama i shvaćanjima uspjeha projekta. Proturječni ciljevi i vizije uspjeha dionika često kompliciraju identifikaciju i rješavanje problema što može rezultirati prekoračenjem trajanja i iznosa u odnosu na planirano. Projekt se ne može smatrati uspješnim ako su ciljevi zadovoljeni samo iz perspektive jednog dionika, dok su ostali nezadovoljni ishodom. Iz ove perspektive postaje ključno analizirati gledišta različitih dionika o uspjehu projekta. Dionici se definiraju kao "skupine ili pojedinci koji imaju udjela u uspješnosti projekta ili očekivanja od njega". Koncept dionika je iznio Freeman (1984), ističući da je ključno prepoznavanje šireg spektra dionika koji imaju različite potrebe, ciljeve i očekivanja te razumijevanje njihove važnosti. Freemanov koncept naglašava važnost održavanja ravnoteže između različitih interesa dionika kako bi se postigao dugoročni uspjeh.

Iako je spektar dionika građevinskih projekata širok i može uključivati investitore, voditelje projekta, projektante, podizvođače, dobavljače, tijela za financiranje, korisnike, zajednicu, lokalne vlasti i ekologe (Bernolak, 1997), relevantni zakoni i propisi u graditeljstvu, kao i praksa upravljanja projektima, obično prepoznaju tri ključna dionika: investitore, izvođače i nadzorne inženjere (Radujković i dr., 2021).

Unatoč velikom broju istraživanja o pokazateljima uspjeha, mjerenju performansi i pristupima upravljanju projektima, u praksi su i dalje česta značajna odstupanja u odnosu na ugovorene iznose i trajanje, osobito u fazi izvođenja radova (Car-Pušić i dr., 2022; Lovrinčević i Vukomanović, 2022). Postojeće metode za ocjenu uspješnosti često zanemaruju dinamiku odnosa između dionika te ne uzimaju u obzir kako različita područja performansi međusobno utječu na krajnji ishod projekta. Većina dostupnih modela fokusira se na retrospektivnu analizu, dok je u građevinskoj praksi sve izraženija potreba za pravovremenim predviđanjem konačnih performansi i ishoda na temelju ključnih pokazatelja uspješnosti koji se mogu prepoznati tijekom izvođenja radova.

Slijedom navedenog, ova doktorska disertacija usmjerava se na fazu izvođenja radova te istražuje uspjeh građevinskog projekta iz perspektive ključnih dionika. Polazište istraživanja čini formiranje teorijskog okvira temeljenog na analizi aktualnih istraživačkih trendova, teorije upravljanja dionicima, percepcije uspjeha u građevinskim projektima te identifikaciji ključnih područja performansi na temelju literature. Poseban naglasak stavlja na povezanost ovih elemenata s procesima digitalizacije i sve većom primjenom suvremenih pristupa, uključujući metode strojnog učenja. Na temelju tog okvira razvija se evaluacijski okvir predviđanja performansi i ishoda projekta, koji povezuje identificirane ključne dionike i područja performansi te

omogućuje dublje razumijevanje problematike. U nastavku, izrađuju se modeli predviđanja prekoračenja ugovorenog trajanja i iznosa, kao i model predviđanja krivulje kumulativnog napretka projekta. Ovi modeli objedinjuju se u podsustav za upravljenje modelima, zamišljen kao dio sustava za podršku odlučivanju.

Svrha ovog istraživanja jest pružiti pravodobnu podršku ključnim dionicima, omogućujući im uvid u potencijalni ishod projekta kako bi unaprijedili kvalitetu procesa donošenja odluka. Predloženi model predstavlja alat za proaktivno upravljanje projektom jer omogućuje identifikaciju kombinacija značajki koje vode prema poželjnim ishodima. Time se osigurava pravovremeno reagiranje na moguće izazove te donošenje informiranih odluka, što u konačnici doprinosi postizanju projektnih ciljeva uz zadovoljstvo svih ključnih dionika. Posebna vrijednost razvijenog modela ogleda se u tome što izvođaču omogućuje pravodobno prepoznavanje i predviđanje mogućih odstupanja te kontinuirano praćenje napretka. Korištenjem ovakvog alata izvođač jasno pokazuje da projekt ne doživljava isključivo kao tehnički zadatak, već kao strateški pothvat kojim potvrđuje svoju posvećenost kvalitetnoj isporuci, otvorenoj komunikaciji, brizi za zaposlenike te učinkovitoj suradnji s investitorom i nadzornim inženjerima. Takav pristup dodatno jača povjerenje među sudionicima projekta, smanjuje mogućnost konflikata i dugoročno doprinosi konkurentskoj prednosti te jačanju reputacije izvođača kao pouzdanog, odgovornog i inovativnog sudionika na tržištu.

1.2. Ciljevi i hipoteze istraživanja

Glavni cilj disertacije je razvoj modela za predviđanje performansi i konačnih ishoda građevinskih projekata, s posebnim naglaskom na prekoračenje ugovorenog trajanja i iznosa. Modeli se razvijaju primjenom metoda strojnog učenja i temelje se na podatcima iz stvarnih građevinskih projekata. Mogu se koristiti u svim fazama izvođenja radova. Za razliku od tradicionalnih pristupa, modeli uzimaju u obzir percepcije ključnih dionika, kontekst izvođenja i dinamiku gradilišta, čime omogućuju pravodobno i precizno prepoznavanje odstupanja od planiranih vrijednosti. Na taj način modeli omogućuju pravovremeno donošenje odluka, povećavaju učinkovitost upravljanja i doprinose ostvarivanju ciljanih ishoda projekta.

U skladu s glavnim ciljem, postavljeno je šest međusobno povezanih pomoćnih ciljeva:

- (1) Razviti teorijski okvir za predviđanje performansi građevinskih projekata;
- (2) Razviti postupak koji se može koristiti u okruženju s više dionika za identifikaciju i rangiranje područja performansi ključnih za postizanje uspjeha građevinskih projekata;

- (3) Uspostaviti vezu između mjerenja i predviđanja performansi projekta kroz razvoj evaluacijskog okvira za predviđanje performansi i ishoda građevinskih projekata koji će omogućiti dublje razumijevanje povezanosti ključnih područja performansi i ishoda građevinskih projekata;
- (4) Razviti i validirati modele predviđanja prekoračenja ugovorenog trajanja i iznosa primjenom metoda strojnog učenja, uz fokus na odabir značajki s većim utjecajem;
- (5) Razviti i validirati model predviđanja krivulje kumulativnog napretka građevinskih projekata koji će, na temelju povijesnih podataka i primjene neuronske mreže, omogućiti preciznije predviđanje napretka projekta;
- (6) Ocijeniti uspješnosti razvijenih modela primjenom na građevinskom projektu u tijeku, analizirajući predviđene ishode te simulirajući scenarij donošenja odluke s ciljem analize utjecaja različitih značajki na konačne ishode i identifikacije optimalnih raspona vrijednosti značajki koji omogućuju postizanje željenih ishoda.

Definirani istraživački ciljevi predstavljaju temelj za formulaciju istraživačkih hipoteza. Njihova provjera omogućuje vrednovanje predloženih modela te identificiranje ključnih pokazatelja uspješnosti.

Glavna hipoteza, H0:

Primjenom teorije upravljanja dionicima i metoda strojnog učenja moguće je razviti kvantitativne modele predviđanja performansi i ishoda građevinskih projekata koji omogućuju pravovremenu procjenu rizika i podršku u donošenju odluka, uz primjenjivost na projekte financirane javnim sredstvima s ugovornim vrijednostima između 7,5 i 25 milijuna eura.

Pomoćne hipoteze:

- (H1) Primjenom teorije upravljanja dionicima i kvalitativne metode višestruke studije slučaja moguće je identificirati ključna područja performansi građevinskih projekata, što predstavlja temelj za razvoj evaluacijskog okvira za predviđanje ishoda projekata.
- (H2) Modele neuronske mreže za predviđanje prekoračenja ugovorenog trajanja i iznosa može se optimizirati odabirom relevantnih ulaznih značajki te prilagodbom arhitekture i hiperparametara modela, čime se povećava točnost predviđanja.
- (H3) Usporedbom s klasičnim matematičkim modelima, primjena neuronskih mreža omogućuje preciznije predviđanje krivulje kumulativnog napretka građevinskih

projekata, pod uvjetom da je model ispravno optimiziran i temeljen na kvalitetno pripremljenim podacima.

- (H4) Simulacije različitih kombinacija značajki na temelju razvijenih modela predviđanja prekoračenja ugovorenog trajanja i iznosa omogućuju identifikaciju intervala vrijednosti koje vode prema postizanju željenih projektnih ishoda.

1.3. Metodologija istraživanja

U istraživanju se primijenjuje integralni pristup koji uključuje kvantitativne i kvalitativne, empirijske i teorijske metode, primjenu statističkih metoda, metoda strojnog učenja i optimizacijskih algoritama. Sinergija različitih metodoloških pristupa osigurava temeljito razumijevanje istraživnog područja, povećava pouzdanost istraživanja, omogućava sveobuhvatnu analizu i predviđanje performansi građevinskih projekata, osiguravajući visoku razinu preciznosti i pouzdanosti rezultata. Kombinacija metoda doprinosi dubljem razumijevanju složenih odnosa među pokazateljima uspješnosti građevinskih projekata te identificiranju ključnih uzroka problema u upravljanju projektima.

Kvantitativna analiza omogućuje prepoznavanje obrazaca među podacima i uključuje izradu baze podataka, primjenu statističkih metoda, metoda strojnog učenja i optimizacijskih metoda. Kvalitativni pristup pruža dublje razumijevanje konteksta u kojem obrasci nastaju i temelji se na polustrukturiranim intervjuima, višestrukoj studiji slučaja (engl. multiple case study) i analizi projektne dokumentacije, čime se osigurava dublje razumijevanje različitih percepcija ključnih dionika.

Teorijske metode (bibliometrijska analiza, sustavno pretraživanje, tematska analiza i kritički pregled znanstvenih izvora) služe za identifikaciju ključnih tema i trendova, razvoj teorijskog i evaluacijskog okvira te definiranje ključnih područja performansi, osiguravajući utemeljenost istraživanja na prethodnim saznanjima i najboljim praksama.

Empirijski dio istraživanja omogućuje prikupljanje i analizu stvarnih podataka s odabranih građevinskih projekata. Provodi se kroz analizu projektne dokumentacije (ugovori o gradnji, aneksi ugovora, mjesečna izvješća o planiranim i realiziranim radovima, komunikacija među dionicima, zapisnici o primopredaji), višestruku studiju slučaja i polustrukturirane intervju s ključnim dionicima građevinskih projekata. Rezultati empirijskog istraživanja služe kao temelj za razvoj evaluacijskog okvira koji omogućuje procjenu performansi građevinskih projekata, povezujući subjektivne percepcije s objektivnim pokazateljima. Ključni element okvira je hijerarhijska struktura ciljeva koja omogućuje precizno definiranje kriterija uspješnosti unutar identificiranih područja performansi te transparentno donošenje odluka.

Od statističkih metoda u istraživanju se primjenjuju deskriptivne i grafičke metode. Deskriptivne metode koriste se za analizu distribucije podataka o građevinskim projektima, uključujući izračun osnovnih statističkih pokazatelja. Grafičke metode koriste se za vizualizaciju trendova i odnosa među varijablama, čime su identificirani ključni obrasci u podacima. Evaluacija i validacija modela temelje se na statističkim metrikama, unakrsnoj validaciji i vizualizaciji rezultata.

U okviru metoda strojnog učenja u istraživanju se primjenjuju neuronske mreže za razvoj modela predviđanja prekoračenja ugovorenog trajanja i iznosa projekta te za razvoj modela krivulje kumulativnog napretka, dok se algoritam slučajne šume (engl. Random Forest, RF) koristi za rangiranje značajki i identifikaciju ključnih pokazatelja uspješnosti. Razvoj ovih modela podupiru optimizacijske metode koje obuhvaćaju optimizaciju arhitekture neuronske mreže i hiperparametara korištenjem slučajnog pretraživanja (engl. random search) i pretraživanja mreže (engl. grid search). Dodatno, primjenjuje se tehnika sintetičkog manjinskog naduzorkovanja za regresiju s Gaussovom šumom (engl. Synthetic Minority Over-sampling Technique for Regression with Gaussian Noise, SMOGN) za generiranje sintetičkih podataka kako bi se uravnotežila distribucija ciljne varijable i poboljšala učinkovitost treniranja modela. Kombinacijom metoda strojnog učenja i optimizacijskih postupaka omogućuje se otkrivanje skrivenih obrazaca u podacima i povećava se preciznost predviđanja. Osim toga, razvijeni modeli koriste se za simulaciju scenarija i testiranje različitih kombinacija ulaznih značajki, čime se provjerava njihova praktična primjena.

Opisano istraživanje donosi sveobuhvatan metodološki okvir koji nadilazi tradicionalne pristupe analizi uspješnosti građevinskih projekata kombinirajući teorijske i empirijske uvide, statističke metode, metode strojnog učenja i optimizacijske metode. Takav pristup doprinosi dubljem razumijevanju složenih odnosa među ključnim pokazateljima performansi te njihovom povezivanju s percepcijama i očekivanjima različitih dionika. Razvijeni evaluacijski okvir i modeli predviđanja integriraju subjektivne i objektivne podatke, omogućuju rangiranje i kvantifikaciju područja performansi te služe kao temelj za simulaciju scenarija i optimizaciju ključnih ulaznih varijabli. Time se pruža praktičan alat za procjenu, praćenje i unapređenje projektnih ishoda, osigurava donošenje informiranih odluka i podiže kvaliteta upravljanja projektima u složenim i dinamičnim uvjetima građevinske industrije.

1.4. Struktura disertacije

Struktura disertacije oblikovana je u skladu s akademskim normama i smjernicama visokoškolske ustanove, uz poštivanje principa jasnoće, sistematičnosti i znanstvene utemeljenosti. Disertacija je koncipirana tako da osigurava dosljedan i logičan razvoj istraživačkih tema te omogući čitateljima postupno razumijevanje istraživačke teme.

Kako bi se osigurala terminološka preciznost, svi ključni pojmovi objašnjeni su na mjestu njihove prve pojave u tekstu.

Disertacija se sastoji od naslovne stranice, sažetka, sadržaja, glavnog teksta, popisa literature, priloga, popisa slika, popisa tablica, popisa kratica te životopisa autora.

Glavni tekst organiziran je u šest poglavlja. Poglavlja su strukturirana tako da postupno uvode čitatelja u istraživačku problematiku, od teorijske osnove i pregleda literature do metodološkog pristupa, analize rezultata i primjene razvijenih modela.

Uvodnim poglavljem pruža se uvid u predmet istraživanja, postavljene ciljeve i hipoteze te se predstavlja metodološki okvir istraživanja.

Drugo poglavlje usmjerava fokus na pregled i analizu dosadašnjih istraživanja te pruža teorijski kontekst i analizu aktualnih istraživačkih trendova. Razmatraju se temeljni principi i razvoj upravljanja projektima, standardi i metodologije te izazovi u suvremenom upravljanju projektima. Posebna pažnja posvećuje se specifičnostima upravljanja dionicima u građevinskoj industriji, njihovom shvaćanju uspjeha te ključnim područjima performansi koja utječu na ishode građevinskih projekata. Nadalje se pruža uvid u primjenu informacijskih sustava za podršku odlučivanju i primjenu umjetne inteligencije i neuronskih mreža u predviđanju performansi projekata. U završnom dijelu poglavlja postavlja se temeljni teorijski istraživački okvir.

Treće poglavlje donosi pregled metodologije istraživanja. Prikazuje se razvoj evaluacijskog okvira za predviđanje performansi i ishoda građevinskih projekata, pri čemu su navedene i objašnjene korištene metode prikupljanja i analize podataka. Nadalje, opisuje se proces razvoja kvantitativnih modela za predviđanje prekoračenja ugovorenog trajanja i iznosa koji se temelje na metodama strojnog učenja i uključuju optimizaciju arhitekture i hiperparametara. Potom se provodi analiza i usporedba matematičkih modela predviđanja krivulje kumulativnog napretka s modelom razvijenim primjenom neuronskih mreža. Poglavlje završava prikazom metoda evaluacije razvijenih modela i vizualizacije rezultata, čime se omogućuje jasnija interpretacija rezultata i identifikacija mogućnosti za unaprjeđenje razvijenih modela.

Četvrto poglavlje prikazuje rezultate istraživanja i raspravlja o performansama razvijenih modela. Uspoređuju se različite kombinacije broja značajki i arhitekture mreže s pripadajućim performansama, pri čemu se identificiraju one koje postižu najbolje rezultate. Na optimalnim modelima provodi se unakrsna validacija kako bi se potvrdila njihova točnost, robusnost i primjenjivost. Analiza evaluacijskih metrika omogućuje detaljnu procjenu preciznosti predviđanja, dok vizualizacija rezultata olakšava interpretaciju te ističe područja za potencijalna unaprjeđenja. Kroz raspravu se analiziraju prednosti i ograničenja razvijenih optimalnih modela te se njihova učinkovitost uspoređuje s postojećim pristupima iz relevantne znanstvene literature.

U petom poglavlju prikazuje se primjena razvijenih modela predviđanja na konkretnom građevinskom projektu, mogućnost adaptivnih ciklusa i primjene u međunarodnom kontekstu. Razvijeni modeli koriste se kao podsustav za upravljanje modelima, predviđen kao dio sustava za podršku odlučivanju, koji omogućuje unos podataka, generiranje predviđanja i izvođenje „što-ako“ analiza. Korištenjem stvarnih podataka s projekta u tijeku oblikuju se simulacijski scenariji s različitim kombinacijama značajki, čime se ispituje učinkovitost modela i potvrđuje njegova primjenjivost u stvarnim uvjetima građevinskih projekata. Nadalje, primjenom metoda klaster analize i Pearsonove korelacije identificiraju se građevinska tržišta sa sličnim trendovima i otvaraju mogućnosti za širu primjenu razvijenih modela izvan lokalnog konteksta.

U završnom, šestom poglavlju donose se zaključci istraživanja, sumiraju nalazi te ističu znanstveni i praktični doprinosi disertacije. Uz pregled ključnih spoznaja i ograničenja provedenog istraživanja, nude se prijedlozi za buduća istraživanja te potencijalni smjerovi daljnjeg razvoja metodologije i modela te otvaraju mogućnosti za daljnje unaprjeđenje područja predviđanja performansi i ishoda građevinskih projekata.

2. PREGLED I ANALIZA DOSADAŠNJIH ISTRAŽIVANJA


U ovom poglavlju prikazan je sustavni pregled dosadašnjih istraživanja s ciljem mapiranja glavnih koncepata i istraživačkih trendova. Poglavlje započinje bibliometrijskom analizom znanstvenih publikacija kako bi se identificirale najčešće korištene ključne riječi, tematski klasteri i razvoj interesa u znanstvenoj zajednici. Slijedi pregled teorijskih i praktičnih temelja upravljanja građevinskim projektima s posebnim naglaskom na standarde, metodologije i izazove koji prate njihovu primjenu u suvremenom kontekstu. Zatim se obrađuje teorija upravljanja dionicima kao jedan od ključnih čimbenika uspješne projektne izvedbe, uz fokus na specifičnosti građevinskog sektora. Posebna pažnja posvećuje se različitim percepcijama uspjeha među ključnim dionicima te načinima evaluacije uspješnosti projekata kroz ključna područja performansi. Dodatno, istražuje se uloga sustava za podršku odlučivanju i primjena neuronskih mreža kao napredne metode strojnog učenja s ciljem unaprjeđenja procesa odlučivanja. Na kraju, poglavlje obrađuje koncept krivulje kumulativnog napretka projekta kao alata za praćenje izvedbe, uz analizu tradicionalnih i suvremenih metoda predviđanja. Ovakav strukturirani pristup omogućuje postavljanje temeljnog teorijskog okvira za daljnje istraživanje s jasnim osvrtom na relevantna područja, identificirane praznine u znanju i potencijalne smjerove za budući razvoj.

2.1. Analiza aktualnih istraživačkih trendova


U svrhu strukturiranog pregleda znanstvenih publikacija i identifikacije aktualnih istraživačkih tema u području građevinskih projekata i sustava za podršku odlučivanju, provodi se bibliometrijska analiza. Prikazana analiza temelji se na prethodno objavljenom istraživanju (Galjanić i dr., 2022), pri čemu je relevantni segment nadopunjen i proširen ažuriranim vremenskim obuhvatom. Analiza omogućuje kvantitativni i objektivni pristup istraživanju kroz statističku analizu prikupljenih bibliometrijskih podataka, identificiranje ključnih tema i analizu njihovog razvoja kroz vrijeme. Za prikupljanje relevantnih znanstvenih publikacija koriste se baze podataka Scopus i Web of Science (WoS).

Slika 1 prikazuje proces definiranja upita i presjek četiriju tematskih skupova čime se istraživački fokus precizno usmjerava na područje interesa. Slika 2 detaljno ilustrira sadržaj svakog polja od kojih se skupovi sastoje. Skup A predstavlja sustav za podršku odlučivanju (engl. decision support system, DSS). Skup B usmjerava pretragu na građevinsku industriju i ključne dionike. Riječi su filtrirane tako da uključuju projekte (engl. project), tvrtke (engl. company), organizacije (engl. organization), inženjere

(engl. engineer) i investicije (engl. investment), ali imaju i zajedničku poveznicu u pojmu izgradnje (engl. construction).



Slika 1. Definiranje upita putem Vennovog dijagrama



Slika 2. Dekompozicija upita za pretraživanje

Skup C uključuje koncepte vezane uz evaluaciju uspješnosti provedbe projekta i usmjerava na pitanja:


- (1) Koji su ključni pokazatelji uspješnosti (engl. key performance indicator, KPI) građevinskih projekata?

- (2) Koji se pristupi koriste za mjerenje performansi (engl. performance measurement) i kako se njima ocjenjuje uspješnost izvedbe projekta (engl. project performance)?
- (3) Što čini uspješno upravljanje projektima (engl. performance management)?
- (4) Koji čimbenici utječu na uspjeh (engl. success) ili neuspjeh (engl. failure) projekata?
- (5) Je li moguće predvidjeti probleme na vrijeme (engl. prediction)?

U pretrazi se koristi oznaka „*” kako bi se pokrilo što više kombinacija ključnih riječi unutar ovih područja. Pretraga obuhvaća razdoblje od siječnja 2000. do veljače 2025. godine (polje D) i uključuje sve vrste znanstvenih publikacija, poput članaka, preglednih radova, konferencijskih radova i knjiga.

Nakon preuzimanja podataka iz baza Scopus i WoS, vrši se inicijalna obrada podataka koja uključuje čišćenje podataka od kategorija koje nisu relevantne za istraživanje, kao što su medicinske i društvene znanosti. Za upravljenje referencama koristi se softver Zotero, pri čemu se podatci izvoze iz baza u RIS formatu. Uklanjanjem duplikata (78 članaka i 20 konferencijskih radova) preostaje 1047 zapisa pogodnih za daljnu analizu. Većina zapisa (75 %) klasificirana je kao znanstveni članci, pri čemu je 4 % navedeno kao pregledni članci. Nadalje, 21 % su konferencijski radovi i prikazi, dok samo 1 % ukupnih podataka čine poglavlja u knjigama. S obzirom na to da se Scopus i WoS uglavnom fokusiraju na članke, a manje na druge vrste publikacija (Martín-Martín i dr., 2018), rezultati su očekivani.

Slika 3 prikazuje trend objavljivanja znanstvenih radova u Scopus i WoS bazama.



Slika 3. Trend objavljivanja publikacija prema postavljenom upitu

Scopusova baza bilježi manji broj podataka te je povećanje objava minimalno. U WoS bazi trend rasta je konstantniji i strmiji. Također je prikazana integrirana baza podataka iz koje su uklonjeni duplikati, a koja dodatno potvrđuje stalni porast interesa. Na početku analiziranog razdoblja interes za ovu temu bio je izrazito nizak, s objavljenih samo 12 radova u prvih pet godina. Značajniji porast broja publikacija započinje 2010. godine. U 2021. godini zabilježena su 94 znanstvena rada, a u 2024. čak 113, što potvrđuje trend rasta znanstvenog interesa za sustave podrške odlučivanju i upravljanje performansama u građevinskim projektima. Analiza povijesnih podataka upućuje na vrlo vjerojatan nastavak rasta broja znanstvenih objava u narednim godinama.

Budući da su ključne riječi pokazatelji glavnih tema istraživanja, nalazi bibliometrijske analize koriste se za izradu vizualizacije. Koristi se VOSviewer, softverski alat dizajniran za stvaranje, vizualizaciju i istraživanje karata temeljenih na podacima. Udaljenost između dvije stavke odražava snagu njihove međusobne povezanosti, što su stavke bliže jedna drugoj, to je njihova veza u literaturi jača. Ukupna snaga veze odražava broj publikacija u kojima se dvije ključne riječi pojavljuju zajedno (Guo i dr. 2019). VOSviewer automatski dodjeljuje stavke u klastere, pri čemu svaki klaster predstavlja skup međusobno povezanih pojmova koji zajedno čine određeno tematsko područje. Ključne riječi koje se često pojavljuju zajedno mogu se tako grupirati i analizirati s ciljem identificiranja dominantnih istraživačkih pravaca unutar odabranog područja. Prag za uključivanje riječi u vizualizaciju postavlja se na minimalno deset pojavljivanja, čime je broj analiziranih ključnih riječi sužen na 103 i omogućena fokusiranija analiza. Tablica 1 prikazuje 20 riječi koje se pojavljuju najčešće i imaju najjaču snagu veze.

Tablica 1. Ključne riječi po učestalosti

Ključne riječi	Ključne riječi (engl.)	Broj ponavljanja
sustavi podrške odlučivanju	decision support systems	240
građevina	construction	145
upravljanje	management	141
sustav	system	131
model	model	130
performanse	performance	114
donošenje odluka	decision making	100
upravljanje projektima	project management	81
građevinska industrija	construction industry	74
sustav podrške odlučivanju	decision support system	68
okvir	framework	65
dizajn	design	65
umjetna inteligencija	artificial intelligence	64
građevinski projekti	construction projects	57


potaknut brzim razvojem inovativnih koncepata koji građevinskoj industriji donosi značajne koristi. U literaturi se često naglašava da živimo u doba industrije 4.0, obilježeno informacijskom tehnologijom, digitalizacijom i pojavom strojeva vođenih umjetnom inteligencijom. Unatoč tome, građevinarstvo se i dalje smatra jednom od najmanje digitaliziranih industrija u svijetu, što ukazuje na potrebu za dodatnim istraživanjima o organizacijskim promjenama potrebnim za digitalizaciju te o evaluaciji i implementaciji digitalnih tehnologija u praksi.

Klaster broj 2 je zelene boje i obuhvaća 29 stavaka među kojima su automatizacija (engl. automation), usporedna analiza (engl. benchmarking), kompjuterska simulacija (engl. computer simulation), građevinska oprema (engl. construction equipment), izvođači (engl. contractors), troškovi (engl. costs), odlučivanje (engl. decision making), učinkovitost (engl. efficiency), ključni pokazatelji uspješnosti (engl. key performance indicator, KPI), ulaganja (engl. investments), upravljanje projektom (engl. project management), izvedba projekta (engl. project performance), analiza rizika (engl. risk analysis) i uspjeh (engl. success). Tematski fokus ovog klastera je dugoročna produktivnost građevinskih projekata. Naglašava važnost povećanja produktivnosti, razvoja opreme i automatizacije radnih procesa. U literaturi se često spominje potreba za poboljšanjem učinkovitosti kroz integraciju naprednih tehnologija i inovacija u upravljanje projektima. Naime, pravilno definirani ključni pokazatelji uspješnosti omogućuju praćenje performansi projekata i usporedbu s industrijskim standardima, čime se doprinosi smanjenju troškova i povećanju kvalitete.

Klaster broj 3, označen plavom bojom, sadrži 23 stavke među kojima su algoritmi (engl. algorithms), umjetna inteligencija (engl. artificial intelligence), klasifikacija (engl. classification), rudarenje podataka (engl. data mining), sustavi za podršku odlučivanju (engl. Decision Support Systems, DSS), teorija odlučivanja (engl. decision theory), stablo odlučivanja (engl. decision trees), prognožiranje (engl. forecasting), neizrazita logika (engl. fuzzy logic), matematički modeli (engl. mathematical models), neuronske mreže (engl. neural networks), optimizacija (engl. optimization), planiranje (engl. planning), predviđanje (engl. prediction) i raspored (engl. scheduling). Ovaj klaster se usmjerava na optimizaciju građevinskih projekata korištenjem umjetne inteligencije, naglašavajući potrebu za optimizacijom procesa radi postizanja konkurentnosti i smanjenja troškova. Razvoj složenih algoritama i modela koji koriste tehnike poput stabla odlučivanja ili neuronskih mreža omogućava predviđanje i analizu rizika i poboljšava proces donošenja odluka. Ujedno, klaster ukazuje na sve veću važnost podataka i analitike u građevinskim projektima te pruža osnovu za razvoj sustava podrške odlučivanju koji mogu pomoći menadžerima u optimizaciji resursa i planiranju. Klaster broj 4 označen je žutom bojom i sadrži 15 pojmova. Uključuje analitički hijerarhijski proces (engl. analytic hierarchy process), razmišljanje temeljem slučaja (engl. case-based reasoning), odabir izvođača (engl. contractor selection), kriterij (engl.

criteria), donošenje odluka (engl. decision-making), model (engl. model), upravljanje lancem opskrbe (engl. supply chain management), podrška (engl. support) i nesigurnost (engl. uncertainty). Ovaj klaster usredotočuje se na održivost i inovacije u građevinskim projektima te naglašava potrebu za ekološki prihvatljivim praksama i rješenjima. Održiva gradnja i cirkularna ekonomija postaju ključni koncepti u industriji, usmjeravajući se na smanjenje otpada, korištenje obnovljivih resursa i promicanje kvalitete života u urbanim sredinama. Klaster ukazuje na promjene u javnim politikama i regulacijama koje potiču razvoj održivih praksi, čime se otvaraju nove mogućnosti za istraživanje i razvoj u građevinskom sektoru.

Usporedbom slike 4, koja prikazuje ključne riječi grupirane u klastere, i slike 5, koja ilustrira korištenje tih ključnih riječi kroz godine, može se uočiti da su termini iz klastera 1 i klastera 4 relativno novi. Ključne riječi na slici 5, označene žutom ili vrlo svijetlozelenom bojom, često se koriste u istraživanjima posljednjih pet godina.



Slika 5. Vizualizacija ključnih riječi (razvoj kroz godine)

Posebno se ističu noviji pojmovi koji se nalaze u crvenom klasteru: BIM (engl. Building Information Modeling), utjecaj (engl. impact), integracija (engl. integration), sustav podrške (engl. support-system) i podrška odlučivanju (engl. decision support). S druge strane, žuti klaster (br. 4) obuhvaća termine kao što su odlučivanje (engl. decision making), nesigurnost (engl. uncertainty) i kriteriji (engl. criteria). Važno je naglasiti da u

ovom području nema plavih ili tamnozelenih pojmova, što ukazuje na to da se u konceptima klastera 1 i klastera 4 još uvijek krije značajan potencijal za daljnja istraživanja. Teme unutar ovih klastera su široke i aktualne, što upućuje na njihovu suvremenost i potencijal za daljnja istraživanja. Analiza ukazuje na raznolikost i širinu istraživačkih pristupa u području građevinskih projekata i sustava podrške odlučivanju. Iako građevinski sektor predstavlja jednu od najvećih industrija u svijetu, i dalje se smatra jednim od najmanje i najsporije digitaliziranih sektora. Digitalna zaostalost sektora naglašava potrebu za dodatnim istraživanjima usmjerenim na organizacijske promjene koje bi omogućile uspješniju integraciju digitalnih alata i sustava. Također, postoji izražena potreba za razvojem sveobuhvatnih metodologija koje bi omogućile evaluaciju i učinkovitu implementaciju digitalnih tehnologija s posebnim naglaskom na fazu izvedbe građevinskih projekata, gdje se očekuju najveće koristi u pogledu povećanja učinkovitosti i smanjenja rizika.

2.2. Standardi, metodologije i izazovi u suvremenom upravljanju projektima

Upravljanje projektima predstavlja interdisciplinarno područje koje objedinjuje teorijska znanja i praktične alate s ciljem učinkovitog planiranja, organizacije i provedbe projekata. Temelji se na jasno definiranim okvirima, metodologijama i procesima koji omogućuju strukturiran i nadziran pristup realizaciji složenih zadataka. Tijekom razvoja discipline oblikovane su različite metodologije i standardi koji su danas sastavni dio stručne prakse.

Na europskom prostoru posebno se ističe metodologija PM², koju razvija Europska komisija radi unaprjeđenja provedbe internih projekata. Danas se koristi i izvan institucija EU te predstavlja cjelovit paket metodologija za upravljanje projektima, programima i portfeljima u organizacijama svih veličina i sektora (European Commission, 2025).

Također, važnu ulogu ima Međunarodna organizacija za upravljanje projektima (engl. International Project Management Association, IPMA), koja razvija vlastiti model kompetencija temeljen na tri dimenzije: tehničkoj, kontekstualnoj i individualnoj. IPMA se fokusira na cjeloviti pristup kompetencijama voditelja projekata, pri čemu uz tehničku stručnost naglašava važnost vodstva, strateškog razmišljanja i interpersonalnih vještina (Hedeman i Riepmma, 2023).

Važnu ulogu ima i Institut za upravljanje projektima (engl. Project Management Institute, PMI), osnovan u Sjedinjenim Američkim Državama, a najpoznatiji po vodiču Project Management Body of Knowledge (PMBOK). PMI promiče standardizirani pristup upravljanju projektima temeljen na jasno definiranim procesima koji

obuhvaćaju sve faze životnog ciklusa projekta, od početnog definiranja, planiranja i provedbe, do nadzora i zatvaranja (PMI, 2004).

Široku primjenu pronašla je i metodologija PRINCE2 (engl. PRojects IN Controlled Environments), razvijena u Ujedinjenom Kraljevstvu. PRINCE2 se temelji na strukturiranom pristupu vođenju projekata kroz jasno definirane faze, zadatke i odgovornosti, uz snažan naglasak na dokumentaciju i upravljanje rizicima. Zbog svoje sistematičnosti, PRINCE2 metodologija je posebno zastupljena u javnom sektoru i velikim infrastrukturnim projektima (ILX Group, 2025).

U suvremenim uvjetima, gdje su promjene brze i česte, sve veću važnost imaju agilne metodologije, razvijene prvenstveno u informatičkom sektoru. Agilni manifest (engl. Agile Manifesto) temelji se na iterativnom razvoju, prilagodljivosti i bliskoj suradnji s korisnicima. Agilni pristupi naglašavaju timsku autonomiju, brze povratne informacije i kontinuirano unaprjeđenje procesa, čime se povećava učinkovitost u kompleksnim i nepredvidivim okruženjima (Agile Manifesto, 2001).

Važno je istaknuti i značaj međunarodne normizacije u ovom području, osobito standarda ISO 21500, koji pruža opće smjernice za upravljanje projektima neovisno o vrsti, veličini ili složenosti. Spomenuti standard omogućuje organizacijama da usklade svoje projektne aktivnosti s globalno priznatim principima, čime se osigurava dosljednost u pristupu i kvalitetu izvedbe (ISO, 2021).

Bez obzira na izbor metodologije, većina suvremenih standarda nastoji ponuditi strukturirani okvir za planiranje, izvođenje, nadzor i zatvaranje projekata, uz naglasak na transparentnu komunikaciju, jasno definirane uloge i odgovornosti te kontinuirano poboljšanje (Grebic, 2019; Jóhannesdóttir, 2019). Osim tehničkih i teorijskih aspekata, upravljanje projektima također zahtijeva razvijene vještine u vođenju timova, učinkovitoj komunikaciji, rješavanju problema i donošenju odluka. U praksi to znači prelazak s tradicionalne hijerarhijske strukture, koja naglašava stroge odnose između nadređenih i podređenih, prema integriranom modelu koji uključuje i vertikalne i horizontalne veze unutar organizacije. Time se potiču otvorena komunikacija i koordinacija unutar projektnog tima, dok vertikalne strukture i odgovornosti ostaju jasne (Kezner i Saladis, 2009).

Iako teorijski okviri pružaju čvrst temelj, praksa često pokazuje drugačiju sliku. U stvarnom poslovnom okruženju pojavljuju se brojni izazovi koji proizlaze iz sve veće složenosti i dinamike. Različiti autori naglašavaju važnost identificiranja ključnih čimbenika uspješnosti, ali i sve veće potrebe za mjerljivim pokazateljima uspješnosti (Chen, 2014; Chen, 2015; Scott-Young i Samson, 2008; Tabassi i Bakar, 2009). Dok se dio istraživanja fokusira na cjelokupni životni ciklus projekta (Chen, 2014; El-Sayegh, 2008; Scott-Young i Samson, 2008), drugi pokušavaju analizirati specifične faze koje mogu imati presudan utjecaj na ishod (Chen, 2015). Uz to, značajan izazov predstavlja i činjenica da različiti dionici često imaju različite percepcije uspješnosti projekta (Davis,

2014; Lovrinčević i Vukomanović, 2022; Montenegro i dr., 2021; Turner i Zolin, 2012; Williams, 2016; Yang i dr., 2018). Neuspjeh projekta često se interpretira kao rezultat nedostatka razumijevanja projektnih zahtjeva i ograničenja, što je posebno izraženo u građevinskoj industriji, gdje su troškovi izgradnje ključni kriterij u donošenju odluka u ranim fazama projekta (Ambrule i Bhirud, 2017).

S obzirom na složeno okruženje i imperativ općeg poboljšanja važno je prepoznati i mjeriti uspješnost projekata u skladu s dugoročnim ciljevima (Hughes i dr., 2017; Mladenovic i dr., 2013; Serra i Kunc, 2015; Williams i dr., 2020). Iako brojni autori naglašavaju važnost ispunjenja kratkoročnih ciljeva, dugoročno orijentiran pristup može donijeti znatnu dodanu vrijednost, osobito u javnim projektima, gdje na uspjeh često utječu i širi društveni i ekonomski konteksti (Flyvbjerg, 2006; Williams i dr., 2020). Pravi uspjeh projekta mjeri se kroz njegov dugoročni doprinos razvoju organizacije i zajednice. Kako bi se ostvario takav uspjeh, potrebno je unaprijediti sustave evaluacije, uključiti više perspektiva dionika te razviti alate koji omogućuju fleksibilnost i prilagodbu tijekom cijelog projektnog ciklusa. Budući da brojni izazovi u upravljanju projektima proizlaze upravo iz složenih odnosa među dionicima, u nastavku se detaljnije razmatra teorija upravljanja dionicima i njezina primjena u građevinskim projektima.

2.3. Teorija upravljanja dionicima

Teorija upravljanja dionicima (engl. stakeholder management theory) naglašava važnost identifikacije, analize te upravljanja interesima i utjecajem različitih dionika unutar procesa donošenja odluka i upravljanja projektima ili organizacijama. Pruža menadžerski okvir i nudi smjernice za konkretno djelovanje u kontekstu višestrukih zahtjeva i očekivanja (Donaldson i Preston, 1995). Primarni cilj teorije upravljanja dionicima jest osigurati da se interesi i potrebe svih relevantnih dionika pravilno identificiraju i uzmu u obzir prilikom donošenja odluka i provođenja aktivnosti. Proces podrazumijeva identifikaciju ključnih dionika, razumijevanje njihovih ciljeva i očekivanja te uspostavljanje sustavne komunikacije i suradnje kako bi se postigla rješenja koja su prihvatljiva i korisna za sve ključne dionike. U praksi se upravljanje dionicima često temelji na spontanim interakcijama i nesustavno razvijenim uzročno-posljedičnim odnosima, što može dovesti do neželjenih ili nepredvidivih ishoda. Istraživanja pokazuju da brojni projekti trpe zbog nedostatka strukturiranih strategija, planova i metoda za učinkovito upravljanje dionicima (Karlsen, 1998). Kako bi se prebrodili izazovi, razvijene su različite metode i smjernice za učinkovitije upravljanje dionicima koje obuhvaćaju planiranje, organiziranje, motiviranje, usmjeravanje i kontrolu resursa (Cleland, 1986; Gilbert, 1983; Jiang i dr., 2002; Savage i dr., 1991).

2.3.1. Razvoj teorije upravljanja dionicima

Teoriju upravljanja dionicima prvi put je predstavio Freeman (1984), naglašavajući njegov dinamički aspekt prema kojem se uloga dionika može mijenjati ovisno o situaciji i razvoju događaja (Fassin, 2010; Winn, 2001). Freeman (1999) sugerira da se organizacije ne bi trebale promatrati isključivo kao poslovni entiteti, već kao složeni sustavi unutar kojih djeluju različite skupine s različitim interesima i ciljevima. Njegov pristup potiče na prepoznavanje što šireg spektra dionika, čime se aktivnosti organizacije usklađuju s interesima svih relevantnih strana. Održavanje ravnoteže između katkad suprotstavljenih interesa dionika ključno je za dugoročni uspjeh organizacije. Organizacije koje u praksi uspješno implementiraju Freemanov koncept često se percipiraju kao društveno odgovornije, što može pozitivno utjecati na njihovu reputaciju i rezultate.

Daljnji doprinos razvoju teorije upravljanja dionicima uključuje pristup Mitchella i dr. (1997) koji se fokusira na identifikaciju, istaknutost i tipologiju dionika. Pristup pomaže menadžerima u razumijevanju tko su potencijalni dionici, koje karakteristike posjeduju i kako mogu utjecati na projekt. Prema Mitchellu, istaknutost dionika ocjenjuje se prema atributima kao što su moć, legitimnost i hitnost, a kombinacija tih atributa definira razred ili vrstu dionika te omogućuje menadžerima da prioritziraju njihove zahtjeve. Teorija upravljanja dionicima tako proširuje tradicionalni pristup poslovanju i potiče organizacije na prepoznavanje svoje šire društvene odgovornosti. Poziva na kontinuiranu analizu dionika, upravljanje njihovim očekivanjima i redovitu prilagodbu strategija u svrhu osiguravanja njihove podrške. U suvremenim uvjetima poslovanja, gdje su interakcije s dionicima vrlo dinamične, primjena teorije upravljanja dionicima jedna je od ključnih pretpostavki uspješnog vodstva i upravljanja projektima. Osim strateškog upravljanja očekivanjima dionika, sve je veća pažnja usmjerena na razumijevanje njihove uloge u generiranju projektne nesigurnosti, osobito u složenim i promjenjivim okruženjima.

Prebanić i Vukomanović (2023) proširuju teoriju upravljanja dionicima u kontekstu infrastrukturnih projekata te naglašavaju da uspjeh nije moguće procijeniti samo kroz tehničke pokazatelje, već i kroz kvalitetu procesa angažmana dionika. Poseban naglasak stavljaju na važnost ravnoteže između tehničkog znanja i interpersonalnih odnosa tijekom upravljanja dionicima.

Ward i Chapman (2008) ističu da dionici predstavljaju značajan izvor neizvjesnosti u projektima zbog različitih i često proturječnih ciljeva. Kako bi se rizici učinkovito upravljali, razvijaju okvir SHAMPU (oblikovanje, upravljanje i vođenje projektnom nesigurnošću, eng. Shape, Harness, and Manage Project Uncertainty) koji se sastoji od devet faza (definiranje projekta, fokusiranje procesa upravljanja nesigurnošću, identificiranje izvora nesigurnosti, strukturiranje pitanja, razjašnjavanje vlasništva,

procjena varijabilnosti, procjena implikacija neizvjesnosti, iskorištavanje planova i upravljanje provedbom) usmjerenih na identifikaciju i upravljanje izvorima nesigurnosti u projektima. Pristup dodatno ističe važnost uključivanja različitih perspektiva dionika pri procjeni uspješnosti projekta, osobito u uvjetima visoke nesigurnosti.

2.3.2. Definiranje i identifikacija dionika


U teoriji i praksi upravljanja projektima dionici se definiraju iz različitih perspektiva, ovisno o kontekstu i pristupu pojedinog autora. Iako se definicije razlikuju u terminologiji i interpretacijama, zajednički im je naglasak na utjecaju dionika na donošenje odluka i konačne ishode projekta ili organizacije. Tablica 2 prikazuje pregled različitih definicija dionika prema relevantnim autorima.

Tablica 2. Definiranje dionika

Autor	Definicija
Freeman, 1984	Svaka skupina ili pojedinac koji može utjecati na ispunjenje cilja organizacije ili na koje to ispunjenje može utjecati.
Donaldson i Preston, 1995	Oni koji doživljavaju ili očekuju potencijalne koristi ili štete kao rezultat djelovanja organizacije.
Cleland, 1998	Ljudi ili skupine koje imaju, ili vjeruju da imaju, legitiman interes prema ključnim aspektima projekta.
McElroy i Mills, 2000	Pojedinac ili skupina koji imaju poseban interes u uspjehu projekta i okruženju u kojem se projekt provodi.
Post i dr., 2002	Oni koji dobrovoljno ili nevoljno doprinose stvaranju ekonomske vrijednosti i aktivnostima organizacije (npr. potencijalni korisnici dobiti ili nositelji rizika).
Phillips, 2003	Osobe koje sudjeluju u donošenju odluka ili ostvaruju koristi od tih odluka.
Newcombe, 2003	Skupine ili pojedinci s uložnim interesima ili očekivanjima vezanim uz projekt.
PMI, 2004	Pojedinci ili organizacije koje su izravno uključene u projekt ili čiji interesi mogu biti pogođeni njegovom provedbom ili ishodom.

Identifikacija dionika predstavlja jedan od najvećih izazova za voditelje projekata (Yang i dr., 2011). Nakon prepoznavanja relevantnih dionika, korisno je analizirati njihove značajke i utjecaj. Mitchell i dr. (1997) razvijaju tipologiju koja se temelji na tri atributa:

moći, legitimitetu i hitnosti. Kombinacija tih atributa omogućuje klasifikaciju dionika u različite razrede (slika 6), što menadžerima olakšava odlučivanje o tome kojim je dionicima potrebno posvetiti više pozornosti, resursa ili komunikacije. Na slici 6 prikazane su pojedine grupe dionika, a u tablici 3 opisane su njihove uloge i utjecaj u kontekstu upravljanja projektima.



Slika 6. Mitchellov model za identifikaciju dionika (prema Mitchell i dr., 1997)

Tablica 3. Objašnjenje razreda dionika (prema Mitchell i dr., 1997)

Grupa	Dionici	Objašnjenje
Latentni dionici	Uspavani dionici	Imaju moć, ali nemaju legitimitet niti hitnost u trenutku. Njihova moć im omogućuje utjecaj, ali ne izražavaju svoje zahtjeve ili interese aktivno.
	Diskrecijski dionici	Imaju legitimitet, ali ne posjeduju moć ili hitnost. Njihovi interesi su opravdani, ali nemaju sredstvo za prisiljavanje organizacije na akciju.
	Zahtjevni dionici	Imaju hitnost, ali ne posjeduju moć ili legitimitet. Njihovi zahtjevi su nužni, ali ne postoje načini na koje mogu ostvariti stvarni utjecaj na organizaciju.
Očekivani dionici	Dominantni dionici	Imaju visoku moć i legitimitet, što im omogućava značajan utjecaj na odluke i strategije organizacije. Oni su ključni igrači u oblikovanju poslovnog okruženja.

	Ovisni dionici	Ovi dionici nemaju moć, ali imaju legitimitet i hitnost. Njihov interes ovisi o odlukama drugih dionika koji imaju moć.
	Opasni dionici	Imaju visoku moć i hitnost, ali nemaju legitimitet. Mogu predstavljati prijetnju organizaciji jer koriste svoju moć za ostvarivanje vlastitih interesa na štetu organizacije.
Definitivni dionici	Imaju visoku moć, legitimitet i hitnost. Njihovi zahtjevi su obavezni za organizaciju i moraju se prioritetno rješavati.	
Nezainteresirane strane	Pojedinci ili grupe koji nemaju ni moć, ni legitimitet, ni hitnost. Nisu uključeni u aktivnosti organizacije, a njihovi interesi ne utječu na poslovne odluke.	

Identifikacija dionika predstavlja temelj uspješnog upravljanja projektima. Pravilna kategorizacija omogućuje usmjeravanje komunikacije, resursa i upravljačkih napora prema onim skupinama koje imaju stvarni utjecaj na tijek i ishod projekta. U dinamičnom kontekstu kao što je građevinski sektor, gdje su odnosi među dionicima višeslojni i često promjenjivi, važnost sustavnog pristupa upravljanju dionicima posebno dobiva na značaju. Upravo u tom okruženju, strateško upravljanje dionicima ne samo da smanjuje rizik nesporazuma, već i povećava šanse za uspjeh projekta kroz usklađivanje interesa i izgradnju odnosa povjerenja.

2.3.3. Upravljanje dionicima u građevinskim projektima

Upravljanje dionicima predstavlja temeljnu pretpostavku uspjeha građevinskih projekata, osobito u kontekstu rastuće složenosti i različitih interesa ključnih dionika. Istraživanja pokazuju da dionici često imaju različite percepcije o uspješnosti projekta, posebno u pogledu ključnih pokazatelja uspješnosti (Toor i Ogunlana, 2010). Zbog toga je njihovo uključivanje u rane faze projekta od presudne važnosti za uspostavu zajedničkog razumijevanja ciljeva i prioriteta (Marović i dr., 2021; Pamučar i dr., 2022; Yang i dr., 2018). Ipak, nastojanje da se ispune svi zahtjevi dionika može stvoriti probleme, osobito kada oni nemaju dovoljno tehničkog znanja ili djeluju iz uske perspektive vlastitih interesa. U takvim slučajevima, udovoljavanje njihovim zahtjevima može izložiti menadžere riziku donošenja odluka koje dugoročno štete projektu. Također, dionici s različitim interesima mogu stvoriti neusklađena očekivanja koja dodatno otežavaju upravljanje projektom.

Za razliku od drugih sektora, građevinski sektor još uvijek u velikoj mjeri zaostaje u sustavnoj primjeni teorije upravljanja dionicima. Oppong i dr. (2017) ističu da u

građevinarstvu često dominira nasumičan pristup upravljanju dionicima. Predlažu konceptualni okvir koji integrira ciljeve upravljanja, čimbenike uspješnosti i pokazatelje učinkovitosti. S obzirom na velik broj uključenih dionika, posebice u velikim projektima, raste potreba za strukturiranim pristupom odnosima. Istraživanja pokazuju da ne postoji univerzalan model za upravljanje tim odnosima, što dodatno ističe potrebu za pristupima prilagođenim specifičnom kontekstu (Kim i Choi, 2015). Uz to, autori naglašavaju da dugoročna uspješnost građevinskih projekata uvelike ovisi o kvaliteti komunikacije među dionicima (Aaltonen i dr., 2008; Bakens i dr., 2005; Yang i dr., 2011; Young, 2006). Cerić (2014) ističe da kvalitetna komunikacija između ključnih dionika značajno doprinosi uspjehu projekta, dok komunikacijski propusti često predstavljaju izvor nesporazuma i konflikata. Povjerenje izgrađeno kroz dugoročne odnose potiče suradnju i smanjuje izloženost projektnim rizicima.

Važno je razlikovati upravljanje dionicima u javnim i privatnim projektima. U javnim projektima, zakonski i proceduralni okviri često ograničavaju izravnu komunikaciju i suradnju dionika jer su odnosi formalizirani kroz centralizirane ugovore (Patrucco i dr., 2021). Nasuprot tomu, privatni projekti omogućuju veću fleksibilnost u oblikovanju odnosa, što otvara prostor za prilagodljivije i učinkovitije oblike suradnje. Brojni autori naglašavaju da bi upravljanje dionicima trebalo biti integrirano u organizacijsku kulturu kao temeljna kompetencija (Hedeman i Riepma, 2023; Minoja, 2012; Post i dr., 2002). Učinkovito upravljanje odnosima s dionicima ne pridonosi samo uspješnosti pojedinog projekta, već dugoročno jača reputaciju, održivost i otpornost organizacije. Kako bi se načela učinkovitog upravljanja dionicima konkretno primijenila u građevinskoj praksi, potrebno je razumjeti tko su ključni dionici i kakvu ulogu imaju u različitim fazama projekta.

Građevinski projekti imaju širok spektar dionika uključujući investitore, voditelje projekta, projektante, podizvođače, dobavljače, tijela za financiranje, korisnike, zajednicu, lokalne vlasti, ekologe (Bernolak, 1997). Sukladno Zakonu o gradnji (NN 153/13, 20/17, 39/19, 125/19, 145/24), stručnoj literaturi i građevinskoj praksi, u fazi izvođenja radova najistaknutiju ulogu imaju tri ključna dionika: investitor, izvođač radova i nadzorni inženjer (Radujković i dr., 2021). Ova osnovna dionička struktura definira ključne odgovornosti i osigurava koordinaciju unutar provedbe građevinskog projekta. U skladu s time, disertacija stavlja poseban naglasak upravo na te ključne dionike, istražujući njihove stavove i percepcije o važnosti različitih područja performansi. S obzirom na njihov značajan utjecaj na tijek i ishod projekta, nužno je razviti cjelovitu i strateški usmjerenu metodologiju koja olakšava usklađivanje interesa i doprinosi realizaciji zajedničkih ciljeva.

2.4. Percepcije uspjeha u građevinskim projektima

Kako bi se razumjela povezanost upravljanja dionicima i ukupne uspješnosti projekta, potrebno je dublje analizirati što uopće čini „uspješan građevinski projekt“ i kako se uspješnost može objektivno mjeriti. Prethodno prikazane razlike u percepcijama dionika jasno ukazuju na to da se uspjeh projekta ne može promatrati kroz jednodimenzionalne pokazatelje. Unatoč brojnim istraživanjima, još uvijek ne postoji univerzalno prihvaćen okvir ili jedinstvena definicija uspjeha projekta. Tradicionalni pristupi analizi uspjeha oslanjaju se na tzv. „željezni trokut“ te prate isporuku projekta s obzirom na troškove, vrijeme i kvalitetu (Abdulhayoglu i Thijs, 2018). S vremenom se pokazalo da takav redukcionistički pristup ne obuhvaća sve važne aspekte složenih građevinskih projekata. Uvođenjem dodatnih parametara i sveobuhvatnijih analiza promatra se složeniji skup podataka, što otežava jedinstven pristup mjerenju uspjeha.

Uspjeh projekta ponajviše ovisi o percepcijama dionika uključenih u projekt. Svaki dionik vrednuje projekt prema vlastitim kriterijima, očekivanjima i interesima (Ika, 2009; Yang i dr., 2018). Primjerice, investitor će projekt najčešće smatrati uspješnim ako je završen unutar ugovorenog trajanja i iznosa, uz očekivanu razinu kvalitete. Izvođaču je važna operativna učinkovitost, dobit i usklađenost s ugovornim obvezama, dok nadzorni inženjer fokus stavlja na dobit, tehničku usklađenost i zakonitost. Takve razlike mogu dovesti do situacije u kojoj jedan dionik projekt doživljava uspješnim, dok ga drugi ocjenjuje kao neuspješan (Hartman, 2002; Toor i Ogunlana, 2008; Yang i dr., 2011).

Uspjeh građevinskog projekta stoga je višedimenzionalan i uvjetovan sposobnošću koordinacije, komunikacije i usklađivanja interesa svih uključenih strana. Iako su trošak, vrijeme i kvaliteta i dalje važni, sve više se u prvi plan stavljaju „meki“ čimbenici, poput komunikacije, odnosa i angažiranosti tima. Cerić (2016) ističe da je upravo povjerenje između ključnih dionika presudno za uspješan tijek projekta jer omogućuje otvorenu razmjenu informacija, brže rješavanje problema i smanjenje konflikata. Transparentna i redovita razmjena informacija, jasno definirane odgovornosti te zajedničko postavljanje ciljeva znatno smanjuju rizik nesporazuma i konflikata (Cleland, 1986; Karlsen, 2015).

Postavljanje jasnih, mjerljivih i realno dostižnih ciljeva usmjerava dionike prema zajedničkim interesima (Kirkman i Rosen, 1999; Scott-Young i Samson, 2008), oblikuje način na koji percipiraju uspjeh projekta i potiče njihov angažman tijekom provedbe. U tom je kontekstu definiranje ciljeva od ključne važnosti. Jedan od pristupa koji pomaže u tome je SMART metoda (engl. specific, measurable, achievable, realistic, timely defined) prema kojoj ciljevi moraju biti specifični, mjerljivi, ostvarivi, realni i vremenski definirani (PMI, 2004). U kontekstu građevinskih projekata, primjena SMART metode olakšava usklađivanje očekivanja među dionicima i omogućuje transparentnije

praćenje napretka. Osim toga, redovita evaluacija performansi projekta predstavlja važan temelj za donošenje odluka i usmjeravanje aktivnosti prema planiranim ishodima (Abdulhayoglu i Thijs, 2018).

Prema smjernicama IPMA-e (Hedeman i Riepma, 2023), uspjeh projekta usko je povezan s ostvarivanjem poslovnih, organizacijskih i interpersonalnih ciljeva. Pojedinač uključen u projekt treba jasno razumjeti vlastitu ulogu i imati definirane ključne pokazatelje uspješnosti, kako bi mogao pratiti napredak i prilagoditi aktivnosti potrebama projekta. Pokazatelji ne uključuju samo tehničke i financijske parametre, već i razinu motivacije, kvalitete komunikacije i razvoj tima. Učinkovita razmjena informacija i povjerenje između dionika pomažu usklađivanju različitih percepcija i povećavaju vjerojatnost da će projekt biti doživljen kao uspješan među svim uključenim dionicima (Hedeman i Riepma, 2023; Muller i dr., 2017). Osim toga, sposobnost prepoznavanja neformalnih utjecaja, hijerarhije i potencijalnih sukoba važna je komponenta u oblikovanju percepcije uspjeha. Razlike u poslovnoj kulturi i komunikacijskim stilovima također oblikuju očekivanja i interpretacije rezultata projekta. Stoga je prilagodljivost, emocionalna inteligencija i pregovaračka vještina nužna za uspješno vođenje projekata s više zainteresiranih strana. U konačnici, fokus na rezultate obuhvaća ne samo ostvarenje postavljenih ciljeva, već i njihovu usklađenost s društvenim, organizacijskim i okolišnim vrijednostima. Uspješan projekt ne podrazumijeva isključivo tehničku ispravnost i financijsku učinkovitost, već i sposobnost da generira dugoročnu vrijednost i doprinosi održivosti (Hedeman i Riepma, 2023; PMI, 2021).

Analizirana istraživanja pokazuju da je uspjeh građevinskog projekta višedimenzionalan i ovisi o percepcijama različitih skupina dionika, kao i o sposobnosti njihove koordinacije i komunikacije tijekom cijeloga životnog ciklusa projekta. Uspješan projekt je onaj koji uspijeva integrirati različite percepcije uspješnosti i stvoriti ravnotežu između kvantitativnih i kvalitativnih pokazatelja koje prepoznaju svi ključni dionici. Kako bi se različite percepcije uspješnosti među dionicima mogle sustavno obuhvatiti i usporediti, istraživanja predlažu njihovu operacionalizaciju kroz ključna područja performansi, što je tema sljedećeg potpoglavlja.

2.5. Opći pregled ključnih područja performansi

Istraživanja pokazuju da je mjerenje performansi jedan od ključnih aspekata uspješnog upravljanja projektima (Toor i Ogunlana, 2010). Iako su tradicionalno u središtu pažnje bili vrijeme, trošak i kvaliteta, suvremeni pristupi naglašavaju potrebu za sveobuhvatnijim sagledavanjem projektne izvedbe. Projektna izvedba predstavlja konkretan tijek aktivnosti i odluka koje se ostvaruju u fazi izvođenja građevinskog projekta, dok se performanse odnose na mjerljive ishode te izvedbe u različitim

područjima. Upravo ti ishodi omogućuju procjenu ukupne projektne uspješnosti. Iz toga proizlazi da se izvedba odražava kroz performanse, a njihova analiza omogućuje procjenu uspješnosti projekta iz perspektive različitih dionika. Uspješnost građevinskog projekta više nije jednoznačno određena isključivo tehničkim ishodima, već uključuje i organizacijske, sigurnosne i interpersonalne čimbenike koji izravno utječu na krajnji ishod i zadovoljstvo dionika. Na temelju pregleda 69 relevantnih publikacija, identificirano je osam najčešće spominjanih područja performansi: kvaliteta, vrijeme, trošak, sigurnost, profitabilnost, produktivnost, zadovoljstvo sudionika i zadovoljstvo investitora (Galjanić i dr., 2023). Odabir tih područja temelji se na učestalosti njihove pojavnosti u literaturi i važnosti koju im autori pridaju u kontekstu projektne uspješnosti. Njihova integracija omogućava višedimenzionalni pristup evaluaciji performansi, koji bolje odražava kompleksnost stvarnih građevinskih projekata. Tablica 4 prikazuje pregled identificiranih područja te njihovu zastupljenost u analiziranoj literaturi.

Tablica 4. Pregled ključnih područja izvedbe za procjenu uspjeha projekta (Galjanić i dr., 2023)

Literatura	Kvaliteta	Vrijeme	Trošak	Sigurnost	Profitabilnost	Produktivnost	Zadovoljstvo sudionika	Zadovoljstvo investitora
Miller, 1984.					+	+		
De Wit, 1988.		+					+	+
Tam i Harris, 1996.	+	+	+	+				
Bernolak, 1997.	+				+	+		
Atkinson, 1999.	+	+	+				+	+
Kagioglou i dr., 2001.	+	+	+	+	+	+		
Chan i dr., 2002.	+	+	+	+			+	+
Cox i dr., 2003.	+	+	+	+		+		
Bassioni i dr., 2004.	+	+	+	+		+		+
Chan i Chan, 2004.	+	+	+	+	+	+		+
Tangen, 2005.	+	+	+		+	+		+
Dawood i dr., 2006.		+	+	+		+		+
Park, 2006.	+	+	+	+		+		
El-Mashaleh i dr., 2007.		+	+	+	+	+		+
Lin i Shen, 2007.			+	+			+	+
Bottazzi i dr., 2008.			+		+	+		
Ling i dr., 2008.	+	+	+					
Nasirzadeh i dr., 2008.		+	+					
Rankin i dr., 2008.	+		+	+		+	+	+
Scott-Young i Samson,	+	+	+	+	+	+	+	+

2008.								
Vidal i Marle, 2008.	+	+	+	+			+	+
Ward i Chapman, 2008.		+	+				+	
Bou-Llusar i dr., 2009.	+	+	+		+	+	+	+
Ling i dr., 2009.	+	+	+	+		+	+	+
Nassar, 2009.	+	+	+	+	+	+		+
Skibniewski i Ghosh, 2009.	+	+	+	+	+	+		
Tabassi i Bakar, 2009.						+		+
Ali i Rahmat, 2010.	+	+	+			+		+
Toor i Ogunlana, 2010.	+	+	+	+	+	+	+	+
Wang i dr., 2010.	+	+	+			+		
Cha i Kim, 2011.	+	+	+	+		+	+	+
Pekuri i dr., 2011.	+		+			+		
Rezaei i dr., 2011.	+					+		+
Turner i Zolin. 2012.	+	+	+				+	+
Chovichien i Nguyen, 2013.	+	+	+	+				+
Peško i dr., 2013.		+	+					
Vukomanović i Radujković, 2013.	+	+	+	+	+	+	+	+
Wanberg i dr., 2013.	+			+				
Xiao i Proverbs, 2013.	+	+	+	+		+		+
Auma, 2014.	+	+	+	+				
Chen, 2014.		+	+					
Nassar i AbouRizk, 2014.	+	+	+	+	+	+		+
Chen, 2015.	+	+	+	+				
Serra i Kunc 2015.	+	+			+	+		
Omar i Fayek, 2016.	+	+	+	+		+		
Silva i dr., 2016.	+	+	+	+	+	+	+	+
Williams, 2016.	+	+	+	+			+	+
Adam i dr., 2017.		+	+					
Cha i Kim, 2017.	+	+	+	+		+		
Chang i dr., 2017.							+	+
Leon i dr., 2017.	+	+	+				+	+
Molwus i dr., 2017.	+	+	+	+			+	+
Oppong i dr., 2017.	+	+	+	+			+	+
Sertyesilisik, 2017.			+		+	+		
Wibowo i dr., 2017.			+		+			
Demirkesen i Ozorhon, 2017.(a)	+	+	+	+			+	
Demirkesen i Ozorhon, 2017.(b)	+	+	+	+			+	+
Tripathi i Jha, 2018.	+	+	+	+	+	+	+	+
Xue i dr., 2018.		+	+					
Keenan i Rostami, 2019.	+		+					+

Montenegro i dr., 2021.	+	+	+					+
Korhonen i dr., 2023.	+	+	+	+		+	+	+
Moradi i dr., 2020.	+	+	+	+		+		+
Radujković i dr., 2021.	+	+	+	+			+	+
Bukoye i dr., 2022.	+	+	+			+	+	+
Patrucco i dr., 2021.	+	+	+	+				
Marović i dr., 2022.	+	+	+	+			+	
Pamučar i dr., 2022.	+	+	+	+		+		
Pavez i dr., 2022.	+	+	+	+		+	+	+

Identificirana područja performansi omogućuju dublji uvid u uspješnost građevinskih projekata iz šire perspektive, međusobno su povezana i ostvaruju uzajamne učinke. U nastavku se detaljnije objašnjava svako područje performansi te se prikazuje kako ih različiti autori opisuju i mjere.

2.5.1. Kvaliteta

Kvaliteta se u literaturi često definira kao razina usklađenosti izvedenih radova s tehničkim specifikacijama, ugovornim zahtjevima i očekivanjima investitora (Bubshait i Almohawis, 1994; Grünberg, 2004; ISO, 2015). Osim što pridonosi tehničkoj ispravnosti građevine, smanjuje troškove održavanja, poboljšava estetske i funkcionalne karakteristike te štiti izvođača od reklamacija i pravnih posljedica (Mallawaarachchi i Senaratne, 2015). Učinkovito upravljanje promjenama u projektnoj dokumentaciji ključno je za očuvanje kvalitete jer nedostatna kontrola može dovesti do kašnjenja i dodatnih troškova (Erdogan i dr., 2005). U literaturi se predlažu različiti pristupi mjerenju kvalitete. Tablica 5 prikazuje primjere izračuna odabranih pokazatelja kvalitete i njihove načine procjene.

Tablica 5. Predloženi pokazatelji kvalitete i načini izračuna

Pokazatelj	Način izračuna	Autor
Usklađenost s očekivanjima korisnika	Skala 1 – 6	Songer i Molenaar (1997)
Opterećenje administracije tijekom izgradnje	Skala 1 – 6	Songer i Molenaar (1997)
Zadovoljstvo investitora projektom u cjelini	Skala 1 – 6	Songer i Molenaar (1997)
Perspektiva investitora, izvođača i treće strane o kvaliteti	Skala 1 – 5	Rad i Khosrowshahi (1998)

2.5.2. Vrijeme

Poštivanje vremenskih rokova od ključnog je značaja za uspješnu provedbu građevinskog projekta jer svako odstupanje može rezultirati ugovornim kaznama za izvođača, dodatnim troškovima rada i opreme, ali i financijskim gubicima za investitora koji može propustiti tržišne prilike (Alavifar i Motamedi, 2014). Zbog toga se upravljanje vremenom temelji na preciznom planiranju i sustavnom praćenju provedbe aktivnosti. Dinamički plan omogućuje pravovremeno prepoznavanje odstupanja te brzo donošenje korektivnih mjera. Ipak, ispunjavanje rokova nije samo odgovornost izvođača. Mnoge aktivnosti, poput dostavljanja potrebne dokumentacije i potvrda, ovise i o drugim dionicima. Istraživanja ističu važnost komunikacije i jasnih procedura zato što odstupanja u dostavi informacija mogu dovesti do lančanih kašnjenja (Cicmil i Gaggiotti, 2009). Poštivanje rokova nije samo tehničko pitanje, već snažno utječe na trošak i percepciju profesionalnosti među dionicima.

Tablica 6 prikazuje primjere izračuna pokazatelja za mjerenje vremenskih performansi prema relevantnoj literaturi.

Tablica 6. Predloženi pokazatelji vremena i načini izračuna

Pokazatelj	Način izračuna	Autor
Prekoračenje vremena (%)	$100 \times (\text{stvarno trajanje} - \text{procjenjeno trajanje}) / \text{procjenjeno trajanje}$	Naoum (1994)
Vrijeme izgradnje	realizirani datum završetka - datum početka	Chan i Chan (2004)
Brzina izgradnje	bruto površina (m ²) / vrijeme izgradnje (dani/tjedni)	Chan i Chan (2004)
Vremenska varijanca (%)	$100 \times (\text{vrijeme izgradnje} - \text{revidirano razdoblje ugovora}) / \text{revidirano razdoblje ugovora}$	Chan i Chan (2004) Al-Meshekeh i Langford (1999)
Učinkovitost planiranja	$100 \times \text{započete aktivnosti} / \text{planirane aktivnosti}$	Dawood i dr. (2006)
Indeks uspješnosti rasporeda	$\text{Ostvarena vrijednost (engl. Earned Value, EV)} / \text{Planirana vrijednost (engl. Planned Value, PV)}$	Dawood i dr. (2006)

2.5.3. Troškovi

Troškovna učinkovitost nadovezuje se na upravljanje vremenom jer kašnjenja često rezultiraju dodatnim financijskim izdacima, čime se izravno utječe na ukupnu uspješnost projekta. Proces obuhvaća planiranje, kontrolu i optimizaciju financijskih

resursa tijekom različitih faza projekta s nepromjenjivim ciljem, postizanjem projektne izvedbe unutar unaprijed definiranih financijskih ograničenja. Ključno je pravovremeno identificirati potencijalna odstupanja od početno planiranog budžeta te primjeniti korektivne mjere (Kravchunovska i dr., 2020). U građevinskom sektoru osobito je važno evidentirati sve dodatne radove, izmjene i nepredviđene troškove koji mogu ukazati na nedovoljno razrađenu projektnu dokumentaciju ili nerealistične početne procjene. Takva odstupanja ne utječu samo na izvođače, već mogu imati i dugoročne posljedice za investitore i krajnje korisnike. Zbog toga transparentno i odgovorno upravljanje financijskim aspektima projekta postaje jedan od ključnih uvjeta njegove ukupne uspješnosti. Kontrola troškova ne može se provoditi izolirano. Zahtijeva jasno definirane ciljeve, transparentnu komunikaciju i razumijevanje potreba svih ključnih dionika.

U tablici 7 prikazani su različiti načini izračuna troška, preuzeti iz dostupne literature.

Tablica 7. Predloženi pokazatelji troškova i načini izračuna

Pokazatelj	Način izračuna	Autor
Prekoračenje troška	Stvarni trošak (\$) – Planirani trošak (\$)	Naoum (1994)
Jedinični trošak	Trošak zgrade (\$)/Bruto površina (m)	Chan (1996)
Indeks performanse troška	Ostvarena vrijednost (engl. Earned Value, EV)/Stvarni trošak (engl. Actual Cost, AC)	Dawood i dr. (2006)

2.5.4. Sigurnost

Sigurnost je neizostavna tema u građevinskim projektima gdje radnici svakodnevno upravljaju teškom opremom, rade na visini i rukuju opasnim materijalima. Sustavno praćenje sigurnosnih standarda i implementacija preventivnih mjera značajno doprinose smanjenju potencijalnih opasnosti (Enshassi, 2003). Sigurnost je neraskidivo povezana s produktivnošću i kvalitetom. Nesreće na gradilištu mogu imati dugoročne posljedice za tim, proračun i reputaciju projekta, pa tako i ugled svih uključenih u njegovu provedbu. Visoka razina sigurnosti ne doprinosi samo zaštiti zdravlja radnika, već pozitivno utječe i na produktivnost. Organizacije koje kontinuirano ulažu u zaštitu na radu bilježe manje zastoja i troškova povezanih s ozljedama, a istodobno uživaju bolju reputaciju. Sigurnost se u literaturi mjeri različitim pokazateljima, poput stope nezgoda i indeksa sigurnosti (Chan i Chan, 2004; Dawood i dr., 2006), a ti pokazatelji mogu poslužiti kao podloga za analizu učinkovitosti sigurnosnih sustava na gradilištu. Visoka razina zaštite radnika ne doprinosi samo fizičkoj sigurnosti, već pozitivno utječe i na moral tima, što dugoročno povećava njihovu motivaciju i ukupnu produktivnost

(Borcherding i dr., 1980). Tablica 8 daje pregled odabranih načina izračuna pokazatelja sigurnosti.

Tablica 8. Predloženi pokazatelji sigurnosti i načini izračuna

Pokazatelj	Način izračuna	Autor
Stopa ozljeda (na 1000 radnika)	1000 x broj ozljeda/broj zaposlenih	Chan i dr. (2002)
Stopa nezgoda	1000 x (ukupan broj nesreća na gradilištu koje je potrebno prijaviti) / (ukupan broj zaposlenih radnika ili odrađenih radnih sati na određenom projektu)	Chan i Chan (2004)
Indeks sigurnosti (1)	1000 x Broj nezgoda / Ukupni radni sati	Dawood i dr. (2006)
Indeks sigurnosti (2)	1000 x Vrijeme izgubljeno na nesreće (sati)/ Ukupno radni sati	Dawood i dr. (2006)

2.5.5. Profitabilnost

Profitabilnost građevinskih projekata definira se kao pozitivna razlika između prihoda i troškova te predstavlja ključan financijski pokazatelj uspješnosti (Cyril i Singla, 2020). Ona odražava održivost i konkurentnost građevinskih poduzeća te opravdanost investicije iz perspektive vlasnika (Au i Hendrickson, 1986; Jahan i dr., 2022). Istraživanja pokazuju da na profitabilnost utječu brojni čimbenici, uključujući promjene cijena materijala, kašnjenja, inflaciju, probleme u opskrbnom lancu i neučinkovito upravljanje resursima (Rajala i dr., 2022; Jahan i dr., 2022).

Unatoč njezinoj važnosti, građevinski projekti često ostvaruju nisku i nestabilnu profitabilnost, osobito u zemljama u razvoju gdje su vremenska, troškovna i organizacijska ograničenja izraženija. Za privatne projekte profitabilnost je ujedno i glavni cilj, dok se u javnim projektima može podrediti društvenim i razvojnim prioritetima (Jahan i dr., 2022).

Tablica 9 prikazuje primjere izračuna pokazatelja profitabilnosti.

Tablica 9. Predloženi pokazatelji profitabilnosti i načini izračuna

Pokazatelj	Način izračuna	Autor
Neto novčani tok	Uplate - troškovi gradnje	Au i Hendrickson (1986)
Povrat na imovinu	Neto dobit / Ukupna imovina	Hindradjaja i Budiman (2019)

Marža zarade prije kamata, poreza, deprecijacije i amortizacije	Zarada prije kamata, poreza, deprecijacije i amortizacije / (Promet + ostali poslovni prihodi) x 100 %	Rajala i dr. (2022)
Povrat na imovinu	(Neto dobit + Financijski rashodi + Porezi) / Prosječna prilagođena bilanca stanja u obračunskom razdoblju x 100 %	Rajala i dr. (2022)

2.5.6. Produktivnost

Produktivnost u građevinskim projektima označava učinkovitost pretvaranja resursa u korisne rezultate, odnosno omjer izlaza i uloženog truda, vremena i sredstava. To je presudan pokazatelj operativne izvrsnosti jer reflektira uspješnu organizaciju timova, optimizaciju upotrebe alata i materijala, kao i kvalitetno planiranje i provedbu radnih zadataka. Projekti se mogu suočiti s ozbiljnim problemima ako se eventualni projektni problemi ne rješavaju na vrijeme. Brza identifikacija problema, žurna reakcija i efikasno rješavanje ključni su za održavanje produktivnosti na željenoj razini. Produktivnost je usko povezana s motivacijom i zadovoljstvom tima kao i s dobro organiziranom logistikom i praćenjem isporuka, što je osobito važno u uvjetima otežane nabave ili poremećaja u lancima opskrbe (Borcherding i dr., 1980). Predloženi načini izračuna prikazani su u tablici 10. Praćenje i analiza produktivnosti omogućuju bolju kontrolu nad izvedbom radova te pravovremeno prepoznavanje potreba za korektivnim mjerama.

Tablica 10. Predloženi pokazatelji produktivnosti i načini izračuna

Pokazatelj	Način izračuna	Autor
Produktivnost	jedinice izlaza/jedinice ulaza	Chew (1988)
Produktivnost	stvarni učinak/očekivani korišteni resursi	Sink i Tuttle (1989)
Produktivnost	ukupna vrijednost/ukupno uloženi resursi	Fisher (1990)
Produktivnost	učinkovitost x efektivnost = vrijeme dodavanja vrijednosti / ukupno vrijeme	Jackson i Petersson (1999)
Produktivnost	(izlaz / ulaz) x kvaliteta = učinkovitost x iskorištenost x kvaliteta	Al-Darrab (2000)

2.5.7. Zadovoljstvo sudionika

Zadovoljstvo sudionika u građevinskom projektu ovisi o ispunjenju njihovih očekivanja tijekom različitih faza realizacije, a oblikuju ga tehničke, sigurnosne i organizacijske značajke projekta, kao i razina međusobnog povjerenja i koordinacije. U kontekstu ovog istraživanja, pod pojmom sudionici podrazumijevaju se ključne osobe koje međusobno surađuju u fazi izvođenja radova kao predstavnici ključnih dionika (predstavnici investitora, izvođača i nadzornih inženjera). Njihova percepcija zadovoljstva značajno utječe na kvalitetu komunikacije, razinu angažiranosti i ukupnu uspješnost projekta. Literatura ukazuje da je zadovoljstvo sudionika višedimenzionalan pojam koji uključuje ne samo tehničke i ugovorne aspekte, već i međuljudske odnose, osjećaj uvažavanja i uključenosti te jasnoću uloga i odgovornosti (Li i dr., 2013). Upravljanje zadovoljstvom nije samo etički imperativ, već i strateški faktor uspjeha jer zadovoljni sudionici pokazuju veću spremnost na suradnju, konstruktivnu komunikaciju i proaktivno rješavanje problema.

Na gradilištu, gdje je suradnja različitih sudionika nužna za pravovremenu i kvalitetnu izvedbu, zadovoljstvo izravno utječe na timsku dinamiku, produktivnost i kvalitetu rada. Singh i Jain (2013) naglašavaju da viša razina zadovoljstva doprinosi većem povjerenju i kreativnosti među sudionicima, dok nisko zadovoljstvo povećava rizik fluktuacije, komunikacijskih problema i konflikata. Gubitak ključnog osoblja tijekom projekta vodi do dodatnih troškova i gubitka specifičnih znanja (Parker i Skitmore, 2005). Dawood i dr. (2006) predlažu praćenje fluktuacije osoblja i pravovremenosti dijeljenja informacija unutar tima kao ključne pokazatelje zadovoljstva. Predloženi načini izračuna prikazani su u tablici 11.

Tablica 11. Predloženi pokazatelji zadovoljstva sudionika i načini izračuna

Pokazatelj	Način izračuna	Autor
Zadovoljstvo sudionika	Skala 1 – 7	Chan i Chan (2004)
Organizacijski stav i komunikacija	Skala 1 – 10	Soetanto i Proverbs (2004)
Zadovoljstvo i učinkovitost projektnog tima	Skala 1 – 10	Kassa i dr. (2023)
Suradnja, spremnost na promjene, rješavanje problema i komunikacija	Skala 1 – 5	Kärnä (2004)
Zadovoljstvo i iskustvo, projektni ciljevi, organizacija, suradnja i komunikacija, sukobi u timu	Skala 1 – 5	Leung i dr. (2004)

2.5.8. Zadovoljstvo investitora

S obzirom da investitori u pravilu snose najveći dio financijskog rizika i imaju ključni interes u uspješnoj isporuci projekta, zadovoljstvo investitora predstavlja jedan od ključnih čimbenika uspješnosti građevinskih projekata. Njihova očekivanja obuhvaćaju ne samo završetak radova u skladu s definiranim iznosima, trajanjem i standardima kvalitete, već i učinkovitost suradnje, razinu komunikacije te ukupnu profesionalnost projektnog tima (Othman, 2014). S druge strane, nezadovoljstvo investitora može voditi neželjenim posljedicama, financijskim penalima, sudskim sporovima ili dugoročnim gubitkom povjerenja, čak i u slučajevima kada su ugovoreni iznos i trajanje projekta formalno ispunjeni. Učinkovita komunikacija između izvođača i investitora, redovito izvješćivanje o napretku projekta i brzo rješavanje potencijalnih problema i reklamacija ključni su preduvjeti za zadržavanje visokog stupnja zadovoljstva. Osim toga, kontinuirano ulaganje u izgradnju povjerenja između svih sudionika, koje podrazumijeva transparentnost oko financijskih pokazatelja, otvorenost glede eventualnih poteškoća i spremnost na kompromis, obično rezultira trajnijim poslovnim odnosima i većom spremnošću investitora da ponovno angažiraju iste stručne timove na budućim projektima (Othman, 2014). Zadovoljstvo investitora objedinjuje sve prethodne pokazatelje, a njegovo očuvanje ključno je za dugoročnu poslovnu održivost. Predloženi načini izračuna prikazani su u tablici 12.

Tablica 12. Predloženi pokazatelji zadovoljstva investitora i načini izračuna

Pokazatelj	Način izračuna	Autor
Indeks zadovoljstva investitora	Skala 1 – 5	Adri i Mursadin (2024)
Zadovoljstvo izvedbom izvođača	Skala 1 – 10	Soetanto i Proverbs (2004)
Zadovoljstvo izvedbom ugovorenog posla, kvalitetom rada, materijalima	Skala 1 – 5	Kärnä (2004)

2.5.9. Zaključno o područjima performansi

U ovom segmentu istraživanja predstavljeni su temeljni koncepti i mogući načini izračuna pokazatelja za identificirana područja performansi te je postavljen temelj za dublju analizu upravljanja projektnim performansama. Jasno je da svako od promatranih područja performansi (kvaliteta, vrijeme, trošak, sigurnost, profitabilnost, produktivnost, zadovoljstvo sudionika i zadovoljstvo investitora) ima svoju specifičnu, ali i međusobno povezanu ulogu u ostvarivanju uspješnosti građevinskog projekta. Iako

se svako područje performansi može zasebno pratiti i evaluirati, njihov puni značaj postaje vidljiv tek kada se promatraju u međusobnom odnosu i u kontekstu šireg upravljačkog okvira. Važno je napomenuti da ključni dionici ne mogu djelovati izolirano. Primjerice, odluke o troškovima mogu smanjiti kvalitetu ili utjecati na zadovoljstvo ako se ne vodi računa o svim relevantnim parametrima. Stoga uspješnost građevinskih projekata ne proizlazi iz optimizacije pojedinačnih područja performansi, već iz koordiniranog i integralnog pristupa koji uravnotežuje tehničke, organizacijske, financijske i interpersonalne aspekte te omogućuje prilagodbu promjenjivim okolnostima na gradilištu. U poglavljima 3. i 4. detaljnije se razmatra kako se opisana integracija očituje iz perspektive različitih ključnih dionika te na koji način doprinosi ukupnoj izvedbi i uspješnosti građevinskih projekata.

2.6. Uloga sustava za podršku odlučivanju u upravljanju građevinskim projektima

Uspješnost građevinskih projekata posebno je izložena rizicima tijekom faze izvođenja, kada dionici svakodnevno donose niz važnih odluka koje izravno utječu na ishod projekta. Upravo faza izvođenja najjasnije otkriva složenost građevinske industrije koju karakterizira višekriterijsko odlučivanje, potreba za praćenjem troškova, resursa, rokova i tehničkih specifikacija, uz stalno prisutne vanjske promjene i ograničene informacije (Boddy i dr., 2007). Iako znanje, iskustvo, stručne kompetencije i timska koordinacija čine čvrstu osnovu sigurnosti u odlučivanju, nesigurnost često proizlazi iz nedostatka ključnih informacija, vremenskog pritiska, složenosti podataka i nepredvidivosti vanjskih čimbenika kao što su tržišne promjene, regulatorni zahtjevi ili tehnički rizici.


Winch (2010) naglašava da se nesigurnost u građevinskim projektima može sagledati kroz dvije međusobno povezane dimenzije: kompleksnost i predvidivost. Kompleksnost se očituje u činjenici da informacije o projektu najčešće postoje, no njihovo prikupljanje i obrada često predstavljaju izazov. Različiti dionici se oslanjaju na različite izvore podataka, što otežava međusobno razumijevanje, usklađivanje i donošenje odluka. S druge strane, predvidivost se odnosi na činjenicu da, iako je moguće prikupiti velik broj podataka, vanjske okolnosti onemogućuju potpuno sigurno predviđanje budućih ishoda projekta. Upravo zbog toga sustavi za podršku odlučivanju postaju ključan alat za smanjenje rizika i donošenje informiranih odluka u stvarnom vremenu (Jajac, 2010; Rogulj i dr., 2017; Tam i dr., 2002).

Kako bi se poboljšala kvaliteta donošenja odluka i smanjila nesigurnost, građevinska industrija sve više primjenjuje informacijske sustave za podršku odlučivanju. Ovi sustavi koriste napredne informacijske tehnologije kako bi olakšali analizu, procjenu i

planiranje, a korisnicima omogućuju interaktivno ispitivanje različitih scenarija i donošenje informiranih odluka. S obzirom na ubrzani proces digitalizacije, potrebu za efikasnijim upravljanjem budžetom i rokovima, kao i sve češću primjenu modela predviđanja i analizu, informacijski sustavi sve više zauzimaju središnje mjesto u donošenju odluka. Iako građevinska industrija tradicionalno zaostaje za drugim sektorima u implementaciji naprednih informacijskih sustava, proces digitalizacije ubrzao se posljednjih godina i sve se više resursa ulaže u integraciju digitalnih alata u svakodnevne upravljačke procese (Jelodar i dr., 2021; Torrecilla-Garcia i dr., 2021).

2.6.1. Donošenje odluka i informacijski sustavi za podršku odlučivanju

Donošenje odluka predstavlja temeljnu funkciju menadžmenta, a kvalitetne odluke izravno utječu na uspješnost organizacije, posebno u složenim i dinamičnim sektorima poput građevinarstva. Prema važnosti, odnosno značenju odluka, odluke se klasificiraju na strateške, taktičke i operativne (Sikavica i dr., 2014). Slika 7 prikazuje podjelu te jasno ilustrira različite razine odlučivanja unutar organizacije.



Slika 7. Hijerarhija odlučivanja (oblikovao autor prema Jajac, 2010 i Marović, 2013)

Strateške odluke donose se na najvišoj organizacijskoj razini i definiraju dugoročnu viziju i smjer razvoja poduzeća, ulazak na nova tržišta, investicije i tehnološke inovacije. Postavljaju okvire kojima se trebaju prilagoditi sve ostale razine odlučivanja. Taktičke odluke operativno provode strateške smjernice te se odnose na srednjoročno planiranje, poput planiranja resursa i definiranja budžeta. U građevinskim projektima, upravo se taktičke odluke ističu kao ključne tijekom faze izvođenja jer se odnose na konkretne aktivnosti na terenu, u uvjetima ograničenog vremena i informacija.

Operativne odluke donose se svakodnevno i tiču se rješavanja konkretnih zadataka, primjerice rasporeda radne snage, logistike materijala ili reakcije na tehničke izazove na gradilištu. One su većinom strukturirane i ponavljajuće, ali mogu imati značajan kumulativni učinak na projektni uspjeh (Keen i Morton, 1978; Jajac, 2010; Marović, 2013; Sikavica i dr., 2014).

Slika 7 također prikazuje dvosmjerni tok informacija između razina odlučivanja. Uzlaznim tokom informacije se prikupljaju, analiziraju i prosljeđuju prema višim razinama radi donošenja odluka, dok se silaznim tokom te odluke operacionaliziraju i provode. Važno je naglasiti da je neprekidan i kvalitetan protok informacija među svim razinama ključan za održavanje cjelovitosti sustava (Jajac, 2010; Marović, 2013).

U cilju podrške odluka, razvijeni su različiti informacijski sustavi koji omogućuju kvalitetnije, brže i informiranije donošenje odluka. Informacijski sustavi grupiraju se u četiri osnovne kategorije (Laudon i Laudon, 2014):

- (1) Sustavi za podršku izvršnim menadžerima (SPI, engl. Executive Support System, ESS) pružaju agregirane informacije iz cijele organizacije u obliku vizualnih prikaza, trendova i makroekonomskih analiza. SPI je namijenjen višem menadžmentu te podržava strateške odluke, kao što su planiranje ulaganja, procjena globalnih rizika ili donošenje korporativnih politika (Keen i Morton, 1978; Sikavica i dr., 2014; Marović, 2013).
- (2) Sustavi za podršku odlučivanju (SPO, engl. Decision Support System, DSS) dizajnirani su za podršku pri rješavanju nestrukturiranih i složenih odluka. SPO sustavi kombiniraju baze podataka, modeliranje, simulacijske metode i interaktivna sučelja, omogućujući menadžerima evaluaciju različitih scenarija, analizu rizika, optimizaciju rasporeda i testiranje opcija (tzv. "što-ako" analize). Omogućuje korisnicima fleksibilnu prilagodbu parametara i evaluaciju posljedica prije donošenja odluke.
- (3) Upravljački informacijski sustavi (UIS, engl. Management Information System, MIS) agregiraju i kategoriziraju podatke dobivene iz sustava za obradu transakcija te generiraju sažete strukturirane izvještaje potrebne za odlučivanje. U praksi se koristi za praćenje napretka projekta, troškova, iskorištenosti resursa i drugih ključnih pokazatelja te podupire donošenje strukturiranih i polustrukturiranih taktičkih odluka.
- (4) Sustavi za obradu transakcija (SOT, engl. Transaction Processing System, TPS) podržavaju operativne odluke, predstavljaju osnovu i koriste se za svakodnevnu evidenciju operativnih podataka, izdavanje dokumenata i izvješćivanje. SOT sustavi pretežito su fokusirani na podatke radi postizanja djelotvornog transakcijskog procesa.

U kontekstu građevinskih projekata, osobito u fazi izvođenja, ključna je uloga SPO sustava zbog njihove sposobnosti da pomognu menadžerima u donošenju brzih, pouzdanih i informiranih odluka. Ovim istraživanjem poseban se naglasak stavlja upravo na tu razinu odlučivanja.

2.6.2. Sustavi za podršku odlučivanju

Nakon pregleda vrste menadžerskih odluka i informacijskih sustava koji ih podržavaju, u nastavku se detaljnije opisuje struktura i klasifikacija sustava za podršku odlučivanju. Sustavi za podršku odlučivanju predstavljaju računalno podržane informacijske sustave osmišljene za olakšavanje donošenja odluka, osobito u slučajevima nestrukturiranih ili polustrukturiranih problema. Njihova primjena posebno dolazi do izražaja u složenim i dinamičnim okruženjima kao što su građevinski projekti, gdje odluke često moraju biti donesene u uvjetima vremenskog pritiska, neizvjesnosti i nepotpunih informacija. Definirani su kao interaktivni, fleksibilni i prilagodljivi informacijski sustavi koji koriste dostupne podatke, modele odlučivanja i baze znanja kako bi pomogli korisnicima u analizi problema i donošenju boljih odluka (Sikavica i dr., 2014; Turban i dr., 2011).

Struktura sustava za podršku odlučivanju temelji se na četiri ključna podsustava (Sikavica i dr., 2014):

- (1) Podsustav za upravljanje podacima (engl. Data Management Subsystem) sadrži baze podataka koje omogućuju pohranu, organizaciju, pretraživanje i obradu relevantnih podataka za konkretne problemske situacije. Funkcija podsustava uključuje i generiranje strukturiranih izvještaja koji olakšavaju donošenje kvalitetnih odluka.
- (2) Podsustav za upravljanje modelima (engl. Model Management Subsystem), poznat i kao sustav za upravljanje bazama modela (engl. Model Base Management System), obuhvaća financijske i statističke modele predviđanja te ostale kvantitativne modele koji omogućuju korisnicima provođenje scenarijskih analiza i testiranje različitih odluka. Ti se modeli mogu klasificirati kao strateški, taktički, operativni i analitički.
- (3) Podsustav za upravljanje znanjem (engl. Knowledge Based Management System) integrira stručna znanja potrebna za donošenje složenih odluka. Podsustav često uključuje ekspertne sustave koji mogu predlagati akcije temeljem prethodnog iskustva i prikupljenog znanja.
- (4) Podsustav za vođenje dijaloga između korisnika i navedenih podsustava ili korisničko sučelje (engl. User Interface Management System, UIMS) omogućuje interakciju korisnika sa sustavom. Kvalitetno korisničko sučelje mora biti

intuitivno, koristiti poznatu terminologiju, omogućiti jednostavnu navigaciju i osigurati brz odaziv sustava.

Sustavi za podršku odlučivanju klasificiraju se prema obilježju sustava (Sikavica i dr., 2014):

- (1) Sustavi temeljeni na podacima (engl. Data-driven DSS, DDSS) omogućuju pristup velikim bazama podataka i njihovu analizu.
- (2) Sustavi temeljeni na znanju (engl. Knowledge-driven DSS, KDSS) oslanjaju se na iskustvo koje se temelji na znanju o nekom području, shvaćanju problema unutar te domene i vještinama za rješavanje nekih od tih problema. Često uključuju metode rudarenja podataka.
- (3) Sustavi temeljeni na dokumentima (engl. Document-driven DSS) fokusirani su na dohvaćanje i obradu nestrukturiranih informacija iz dokumenata i mrežnih izvora.
- (4) Sustavi temeljeni na komunikaciji (engl. Communications-driven DSS, CDSS) i sustavi za podršku grupnom odlučivanju (engl. Group DSS, GDSS) osiguravaju alate za zajedničko odlučivanje, razmjenu informacija i suradnju u realnom vremenu.
- (5) Sustavi temeljeni na modelima (engl. Model-driven DSS, MDSS) koriste kvantitativne modele za analizu problema i optimizaciju rješenja.

U građevinskim projektima, naročito u fazi izvođenja, menadžeri i inženjeri svakodnevno donose taktičke odluke koje često imaju značajan financijski i vremenski utjecaj. Zbog dinamičnih okolnosti, odluke moraju biti donesene brzo, uz ograničene informacije. U tom kontekstu sustavi za podršku odlučivanju omogućuju integraciju aktualnih podataka, analizu scenarija i procjenu posljedica odluka. Umjesto da se oslanjaju isključivo na statične izvještaje ili iskustvo, menadžeri i inženjeri mogu uz pomoć SPO sustava testirati različite opcije, simulirati ishode i odabrati optimalan smjer djelovanja (Torrecilla-Garcia i dr., 2021).


Prednosti primjene sustava za podršku odlučivanju uključuju brže donošenje odluka, bolju upotrebu dostupnih informacija, povećanu točnost, poboljšanu suradnju među timovima, veću organizacijsku kontrolu i u konačnici konkurentsku prednost. Ipak, prekomjerno oslanjanje na takve sustave može dovesti do smanjenja osobnih vještina donošenja odluka, percepcije gubitka autoriteta i preopterećenosti informacijama. Nužno je osigurati pravilnu integraciju SPO sustava u organizacijski kontekst i njihovu primjenu kao podršku, a ne zamjenu menadžerske prosudbe (Sikavica i dr., 2014).

S obzirom na sve veću količinu podataka i potrebu za brzim, pouzdanim odlučivanjem u složenim uvjetima građevinskih projekata, sustavi za podršku odlučivanju sve češće se oslanjaju na napredne metode umjetne inteligencije. U nastavku se prikazuje odnos

između umjetne inteligencije, strojnog i dubokog učenja te se obrađuju ključne metode korištene za izradu modela predviđanja.

2.7. Umjetna inteligencija, strojno i duboko učenje

Razvoj umjetne inteligencije (engl. Artificial Intelligence, AI) transformirao je način na koji računalni sustavi analiziraju podatke, prepoznaju obrasce i donose odluke uz minimalan ljudski nadzor. Umjetna inteligencija nalazi primjenu u mnogim sektorima, uključujući medicinu, financije i građevinarstvo, gdje može poslužiti za predviđanje troškova, optimizaciju resursa i analizu konstrukcijskih podataka (Kelleher, 2019). Slika 8 prikazuje hijerarhijski odnos između umjetne inteligencije, strojnog učenja i dubokog učenja.



Slika 8. Odnos između umjetne inteligencije, strojnog učenja i dubokog učenja (Kelleher, 2019)

U okviru umjetne inteligencije razvijen je niz metoda strojnog učenja (engl. Machine Learning, ML), koje omogućuju računalima da uče iz podataka bez potrebe za eksplicitnim programiranjem svih pravila. Umjesto da slijede unaprijed definirane naredbe, modeli strojnog učenja analiziraju velike količine podataka kako bi identificirali obrasce i generalizirali stečeno znanje na nove situacije (Bishop, 1994; Goodfellow i dr., 2016). U strojnom učenju ističe se algoritam slučajne šume, metoda koja se temelji na kombiniranju većeg broja stabala odlučivanja radi povećanja točnosti i robusnosti modela. Algoritam slučajne šume je poznat po svojoj otpornosti na prenaučenosť te po mogućnosti interpretacije važnosti pojedinih varijabli (Breiman, 2001).

Duboko učenje (engl. Deep Learning, DL), kao podskup strojnog učenja, temelji se na uporabi višeslojnih neuronskih mreža koje omogućuju modeliranje složenih, nelinearnih odnosa u podacima. Zbog visoke preciznosti predviđanja, duboko učenje je sveprisutno u područjima kao što su računalni vid, obrada prirodnog jezika i prediktivna analitika (LeCun i dr., 2015).

Budući da su neuronske mreže temeljna metoda korištena u razvoju modela predviđanja u ovoj doktorskoj disertaciji, u sljedećem poglavlju detaljnije se prikazuje njihovo funkcioniranje, arhitektura te najvažniji parametri i hiperparametri.

2.7.1. Uvod u neuronske mreže

Neuronske mreže (engl. Neural Networks, NN) predstavljaju jednu od najznačajnijih metoda dubokog učenja, inspiriranu načinom na koji funkcionira ljudski mozak. Temelje se na sustavu povezanih umjetnih neurona organiziranih u slojeve, pri čemu se podatci obrađuju pomoću složenih matematičkih operacija (Islam i dr., 2019). Prvi matematički model neuronske mreže predstavili su McCulloch i Pitts (1943), dok je Rosenblatt (1958) razvio perceptron, prvi funkcionalni model učenja temeljen na neuronskim mrežama. Ograničenja perceptrona u rješavanju složenijih problema nadvladana su 1980-ih razvojem višeslojnih perceptrona (engl. multilayer perceptrons, MLP) i algoritma povratnog širenja pogreške (engl. backpropagation) koji su omogućili treniranje dubljih mreža (Rumelhart i dr., 1986).

Zahvaljujući sposobnosti da uče iz iskustva, prepoznaju složene obrasce i donose odluke u uvjetima neizvjesnosti, neuronske mreže predstavljaju jednu od najsnažnijih metoda umjetne inteligencije (LeCun i dr., 2015). U doba digitalne transformacije, gdje se generiraju ogromne količine informacija, klasične metode analize često ne mogu obuhvatiti sav dostupan sadržaj. Neuronske mreže, s druge strane, omogućuju analizu kompleksnih i velikih skupova podataka, bilo da je riječ o milijunima slika, senzorskih očitavanja ili financijskih transakcija. Kelleher i Tierney (2018) ističu da se čak 80 % vremena u projektima strojnog učenja utroši na pripremu podataka, što dodatno naglašava važnost njihove integracije s postojećim informacijskim sustavima radi lakše dostupnosti, automatskog prikupljanja i ažuriranja podataka. Prednosti neuronskih mreža uključuju sposobnost analize velikih količina podataka, otpornost na šum i pogreške u podacima te mogućnost automatizacije procesa donošenja odluka. Međutim, izazovi primjene uključuju visoke računalne zahtjeve, potrebu za velikim količinama kvalitetnih podataka i često ograničenu interpretabilnost rezultata. Njihova učinkovitost najveća je kada su istrenirane na opsežnim i raznovrsnim skupovima podataka, dok nedostatni ili pristrani podatci mogu dovesti do nepouzdanih odluka. Treniranje dubokih mreža pritom zahtijeva snažnu hardversku podršku i dugotrajne postupke obrade. Dodatni izazov predstavlja složenost modela, neuronske mreže su

složene što ih čini teškima za tumačenje. Često se opisuje da funkcioniraju kao crne kutije jer je vrlo teško razumjeti kako su došle do određenog zaključka (Goodfellow i dr., 2016; LeCun i dr., 2015).


Brojna istraživanja usmjerena su na primjenu neuronskih mreža u predviđanju ključnih varijabli građevinskih projekata. Neuronske mreže su se pokazale posebno učinkovitima u rješavanju složenih problema, a njihova primjena u istraživanju upravljanja građevinskim projektima raste tijekom posljednjih nekoliko desetljeća (Liu i dr., 2021). Kim i dr. (2004) ističu važnost veličine skupa podataka za preciznost predviđanja, dok Cheng i dr. (2010) naglašavaju ključnu ulogu odabira ulaznih značajki i arhitekture mreže. Zhang (2016) ističe potrebu za integracijom organizacijskih i komunikacijskih čimbenika u modele predviđanja. Chao i Chien (2009) pokazuju da model neuronske mreže koji koristi kombinaciju podataka, poput iznosa ugovora, trajanja, vrste posla i lokacije projekta, može značajno unaprijediti preciznost predviđanja. Ko i Cheng (2007) razvijaju evolucijski model za predviđanje uspjeha projekta koristeći podatke o napretku i obavezama na projektu, financijske indikatore, resurse i sigurnosne parametre. Također, brojne studije potvrđuju primjenjivost neuronskih mreža u predviđanju trajanja i financijskih pokazatelja projekata. U radovima Petruseva i dr. (2012), Trijetija i dr. (2023), Al Mnaseera i dr. (2023) te Velumaniya i dr. (2021) istaknuta je njihova superiornost u usporedbi s tradicionalnim pristupima. Car-Pušić i dr. (2022) predstavljaju modele temeljene na neuronskim mrežama za predviđanje trajanja i troškova izgradnje autocesta u Hrvatskoj. Leśniak i Juszczak (2018) te Tijanić Štrok i dr. (2019) primjenjuju neuronske mreže za predviđanje troškova, dok se Alsugaira i dr. (2023) i Shihadeh i dr. (2024) fokusiraju na trajanje građevinskih projekata. El-Sawah i Moselhi (2014) testiraju različite vrste neuronskih mreža za procjenu troškova.

Usporedbe s tradicionalnim regresijskim modelima pokazuju da neuronske mreže, kao i drugi oblici mekog računarstva poput neizrazite logike, modela potpornih vektora ili XGBoosta, često postižu veću točnost i bolje prepoznaju nelinearne odnose među varijablama (Coffie i Cudjoe, 2023; Coffie i Cudjoe, 2024; Obianyo i dr., 2022; Senouci i dr., 2016).

2.7.2. Arhitektura, parametri i hiperparametri neuronske mreže

Neuronske mreže temelje se na arhitekturi sastavljenoj od međusobno povezanih jedinica koje se nazivaju neuroni. Informacije se prenose kroz mrežu putem veza koje sadrže pridružene težine, a njihova prilagodba tijekom procesa učenja omogućuje mreži da modelira kompleksne odnose među podacima. Osnovnu arhitekturu mreže čine ulazni sloj, jedan ili više skrivenih slojeva te izlazni sloj, pri čemu svaki sloj ima specifičnu funkciju u obradi podataka (Chua i dr., 1997; Doroshenko, 2020). Ulazni sloj

(engl. input layer) prima podatke iz vanjskog okruženja i proslijeđuje ih u mrežu. Skriveni slojevi (engl. hidden layers) vrše ključnu obradu podataka, otkrivajući obrasce i relacije kroz primjenu aktivacijskih funkcija. Izlazni sloj (engl. output layer) generira konačna predviđanja na temelju prethodno obrađenih informacija (Bishop, 1994). Broj slojeva i broj neurona unutar svakog sloja određuje kapacitet modela za učenje i ovisi o složenosti problema koji se analizira. Slika 9 prikazuje tipičnu arhitekturu neuronske mreže.



Slika 9. Tipična arhitektura neuronske mreže (Kim i dr., 2004)

Učinkovita primjena neuronske mreže zahtijeva treniranje na reprezentativnom skupu podataka. Svaki ciklus treniranja sastoji se od dvije ključne faze: proslijeđivanja unaprijed (engl. forward propagation) i povratnog širenja pogreške (engl. backpropagation). U fazi proslijeđivanja unaprijed podatci se prenose iz ulaznog sloja prema izlaznom, a izlazne vrijednosti izračunavaju se na temelju trenutnih težina mreže. Nakon toga slijedi faza povratnog širenja pogreške, u kojoj se računa razlika

između stvarne i predviđene vrijednosti, a pogreška se propagira unatrag kroz mrežu kako bi se optimizirale težine i smanjila ukupna pogreška (Goodfellow i dr., 2016).

Najvažniji parametri modela koji se prilagođavaju tijekom treniranja su sljedeći:

- (1) Težine (engl. weights) predstavljaju ključne vrijednosti koje određuju utjecaj pojedinog neurona na izlaz mreže.
- (2) Pristranost (engl. bias) pomaže modelu da bolje nauči odnose u podacima. Uklanja ovisnost izlaza o isključivo ulaznim vrijednostima osiguravajući fleksibilniju prilagodbu mreže.

Za učinkovito treniranje neuronskih mreža ključno je pravilno postavljanje hiperparametara koji određuju kako i koliko brzo model uči. Ključni hiperparametri koji se postavljaju prije treniranja modela su sljedeći (Goodfellow i dr., 2016):

- (1) Stopa učenja (engl. learning rate) određuje veličinu koraka kod ažuriranja težina mreže. Preniska vrijednost usporava treniranje, dok previsoka može uzrokovati oscilacije.
- (2) Moment (engl. momentum) kontrolira brzinu prilagodbe modela i pomaže u izbjegavanju lokalnih minimuma.
- (3) Veličina serije podataka (engl. batch size) označava broj uzoraka koji se obrađuju prije ažuriranja parametara mreže. Manja veličina serije podataka vodi ka češćim ažuriranjima i omogućuje bržu prilagodbu, dok veća pruža pouzdanije gradijente i osigurava stabilnije učenje.
- (4) Broj epoha (engl. epochs) definira koliko puta mreža prolazi kroz cijeli skup podataka tijekom treniranja. Premalo epoha može dovesti do nedovoljnog učenja (engl. underfitting), dok preveliki broj epoha može uzrokovati prekomjerno prilagođavanje (engl. overfitting).
- (5) Optimizator (engl. optimizer) upravlja ažuriranjem težina mreže kako bi se minimizirala pogreška modela. Najčešći optimizatori su SGD, Adam i RMSprop.
- (6) Funkcija gubitka (engl. loss function) kvantificira razliku između predviđenih i stvarnih vrijednosti. Za regresijske zadatke najčešće se koristi srednja kvadratna pogreška.
- (7) Regularizacija (engl. regularization) smanjuje rizik od prenaučenosti, primjerice korištenjem metode nasumičnog isključivanja dijela neurona tijekom treniranja (engl. dropout) ili primjenom L2 regularizacije.
- (8) Aktivacijska funkcija (engl. activation function) određuje način prijenosa informacija između slojeva mreže. Najčešće korištene aktivacijske funkcije su rektificirana linearna jedinica (engl. Rectified Linear Unit, ReLU), tanh i sigmoid.

- (9) Mehanizam ranog zaustavljanja (engl. early stopping) prekida treniranje modela ako se pogreška na validacijskom skupu ne smanjuje kroz određeni broj epoha, čime se sprječava prekomjerno prilagođavanje.

Neuronske mreže u građevinskim projektima nalaze primjenu u širokom spektru zadataka, uključujući predviđanje trajanja i iznosa, procjenu rizika, optimizaciju rasporeda izvođenja te predviđanje produktivnosti rada. Među ostalim mogućnostima, ističe se i njihova primjena u predviđanju krivulje kumulativnog napretka, čime se omogućuje pouzdana vizualizacija dinamike radova kroz vrijeme i analitička usporedba između planirane i stvarne izvedbe.

2.8. Krivulja kumulativnog napretka projekta

Nastavno na prethodno istaknute izazove složenosti, neizvjesnosti i potrebe za preciznim predviđanjem u građevinskim projektima, osobitu važnost ima praćenje napretka pomoću krivulja kumulativnog napretka. Takve krivulje vizualno prikazuju akumulaciju resursa, troškova i drugih mjernih podataka kroz vrijeme, omogućujući usporedbu planiranih i stvarnih rezultata te donošenje pravovremenih i informiranih odluka tijekom realizacije (PMI, 2017; Tijanić Štrok i Car-Pušić, 2017). Uspješnost upravljanja građevinskim projektima uvelike ovisi o dostupnosti točnih i pravovremenih podataka o napretku. Krivulje napretka omogućuju prepoznavanje odstupanja, analizu učinkovitosti te korekciju tijekom realizacije. Iako inženjeri često kroz iskustvo razvijaju osjećaj za prepoznavanje obrazaca napretka, analize pokazuju da su stvarne krivulje često znatno različite od planiranih, što može biti posljedica lošeg planiranja, vremenskih uvjeta, financijskih ograničenja ili organizacijskih poteškoća (Stanojlovic i Cirovic, 2016).

Dva metodološka pristupa često se koriste u znanstvenom istraživanju: idiografski (usmjeren na analizu pojedinačnih slučajeva) i nomotetski (usmjeren na prepoznavanje univerzalnih obrazaca na temelju kvantitativnih podataka). Predmetno istraživanje primjenjuje nomotetski pristup zbog njegove sposobnosti generalizacije i oblikovanja modela predviđanja (Dzwigol, 2022; Ostojić-Škomrlj i Radujković, 2012). No, upravo ograničena fleksibilnost tradicionalnih nomotetskih modela u uvjetima nelinearnosti i kompleksnosti građevinskih projekata naglašava potrebu za naprednijim rješenjima.

Tradicionalni matematički modeli naširoko su korišteni za predviđanje oblika krivulja kumulativnog napretka u građevinskim projektima. Njihova glavna prednost leži u relativnoj jednostavnosti, mogućnosti prilagodbe poznatim obrascima i širokoj dostupnosti potrebnih alata za njihovu implementaciju. Jedan od najraširenijih pristupa su regresijski modeli, a polinomski izrazi posebno se izdvajaju zbog matematičke fleksibilnosti i prilagodljivosti različitim vrstama podataka (Ostojić-

Škomrlj i Radujković, 2012). Sličan pristup predstavlja i Peerov model (1982), koji koristi povijesne podatke projekata za aproksimaciju oblika krivulje. Uz regresijske, široko su primijenjeni i statistički modeli, koji se temelje na funkcijama distribucije vjerojatnosti. Beta distribucija omogućuje realističan prikaz početnog sporog rasta, ubrzane faze sredinom projekta te usporavanja prema kraju (Bhaumik, 2016). Weibullova distribucija nudi fleksibilan okvir za analizu podataka o pouzdanosti, vremenskim rasporedima i troškovima, što ju čini pogodnom za složene projekte s više faza (Nassar i dr., 2005). Rayleighova distribucija, iako tradicionalno razvijena za modeliranje brzine vjetra i kontrole kvalitete, pokazala je potencijal i u drugim područjima (Obi i dr., 2024). Logistička distribucija koristi se u situacijama u kojima se resursi troše postupno i u uvjetima ograničenih kapaciteta, što je čest slučaj u građevinskim projektima s etapnim izvođenjem radova (Kucharavy i De Guio, 2012). Posebnu kategoriju čine funkcije rasta, kao što je Gompertzova funkcija, koja se pokazala posebno učinkovitom u predviđanju troškova temeljenih na podacima prikupljenima tijekom projekta (Nannini i dr., 2017). Uz navedene pristupe, razvijeni su i segmentni modeli, poput onih koje su predstavili Boussabaine i Elhag (1999), a koji omogućuju procjenu novčanih tokova s naglaskom na faze naplate u uvjetima visoke neizvjesnosti.

Unatoč širokoj primjeni, tradicionalni modeli imaju određena ograničenja. Većina zahtijeva prethodnu kategorizaciju projekata prema specifičnim parametrima, poput veličine tvrtke, trajanja projekta, metode izvedbe, vrijednosti ugovora i sličnog (Kaka i Price, 1993). Za svaku kategoriju potrebno je izračunati specifične vrijednosti parametara. Problem se javlja kada projekt istovremeno obuhvaća obilježja više kategorija ili ne pripada jasno nijednoj od njih, čime tradicionalni modeli gube sposobnost da integriraju sve relevantne uvjete u jedinstven okvir predviđanja. Takva ograničena fleksibilnost smanjuje preciznost i korisnost u praksi. Ograničenja tradicionalnih modela u pogledu prilagodbe stvarnim, višedimenzionalnim projektnim uvjetima otvaraju prostor za inovativnije i podatkovno osjetljivije pristupe.

U kontekstu industrije koja se brzo mijenja, a informacije često ostaju nepotpune ili proturječne, ključ uspjeha predviđanja leži u alatima koji mogu prepoznati obrasce, razumjeti odnose među varijablama i adaptirati se u stvarnom vremenu. U tom kontekstu, metode strojnog učenja predstavljaju suvremeni pristup koji nadilazi statičke okvire klasičnih modela i omogućuje preciznija, fleksibilnija i robusnija predviđanja. Posebno su učinkovite u obradi i analizi velikih skupova podataka, prepoznavanju skrivenih obrazaca i nelinearnih odnosa, otpornosti na nepotpune ili šumom opterećene podatke te u mogućnosti generalizacije naučenih obrazaca na nove i prethodno neviđene situacije (LeCun i dr., 2015). Osim kvantitativnih pokazatelja, dodatna vrijednost strojnog učenja ogleda se u njegovoj sposobnosti da prilagodi modele specifičnim karakteristikama svakog projekta, bez potrebe za ručnim

definiranjem kategorija. Za razliku od tradicionalnih metoda koje zahtijevaju kategorizaciju, neuronske mreže automatski uče iz podataka i same oblikuju logiku. Time se povećava fleksibilnost, ubrzava proces predviđanja i smanjuje mogućnost pogreške uzrokovane ljudskom prosudbom.

Rastući broj istraživanja jasno pokazuje kako primjena strojnog učenja ima velik potencijal za unaprjeđenje procesa planiranja i kontrole u građevinskoj industriji (Alsugaira i dr., 2023; Car-Pušić i dr., 2022; Chao i Chien, 2009; Coffie i Cudjoe, 2023; Coffie i Cudjoe, 2024; El-Sawah i Moselhi, 2014; Leśniak i Juszczuk, 2018; Obianyo i dr., 2022; Tijanić Štrok i dr., 2019; Senouci i dr., 2016; Shihadeh i dr., 2024). Ipak, izazov ostaje u osiguravanju dovoljno kvalitetnih i reprezentativnih podataka, kao i u razvoju modela koji su, uz visoku točnost, istovremeno jednostavni, intuitivni i lako primjenjivi u svakodnevnoj inženjerskoj praksi. Iz tog razloga, u disertaciji se uspoređuju performanse tradicionalnih matematičkih modela i neuronskih mreža na stvarnim podatcima građevinskih projekata, s ciljem identificiranja modela predviđanja kumulativnog napretka veće preciznosti i prilagodljivosti različitim uvjetima projekta.

2.9. Integracija teorijskih pristupa u kontekstu upravljanja građevinskim projektima

Pregled literature ukazuje na kompleksnost istraživnog problema upravljanja građevinskim projektima te ističe potrebu za holističkim i multidisciplinarnim pristupom uz aktivno sudjelovanje svih relevantnih dionika. Identificirani su ključni izazovi koji se prvenstveno odnose na probleme usklađivanja različitih interesa dionika, nejasnoće u definiranim ulogama te nedostatnu koordinaciju.

Analizom aktualnih istraživačkih trendova potvrđeno je kako suvremena istraživanja zahtijevaju integraciju raznovrsnih teorijskih koncepata te multidimenzionalni pristup upravljanju građevinskim projektima. Istaknuta je važnost usvajanja suvremenih standarda i metodologija, što je ključno za uspješnu realizaciju složenih građevinskih projekata. Kao temeljni teorijski okvir odabrana je teorija upravljanja dionicima. Njezina važnost proizlazi iz sposobnosti da detaljno adresira sukobe interesa, kompleksne međuljudske odnose i komunikacijske izazove karakteristične za građevinski sektor. Analizom percepcija uspjeha među ključnim dionicima potvrđena je potreba za višedioničkom perspektivom, zajedničkim razumijevanjem ciljeva te usklađenim pristupom evaluaciji uspješnosti. Osam identificiranih područja performansi (kvaliteta, vrijeme, trošak, sigurnost, profitabilnost, produktivnost, zadovoljstvo sudionika i investitora) ukazuju na važnost integriranog i uravnoteženog upravljanja svim aspektima izvedbe projekta. Svako od ovih područja predstavlja

ključne indikatore uspjeha koji moraju biti strateški upravljani kako bi se povećala ukupna učinkovitost projekta i zadovoljstvo ključnih dionika.

Nadalje, naglašena je važna uloga sustava za podršku odlučivanju u unaprjeđenju procesa upravljanja građevinskim projektima. Njihova primjena omogućava strukturiranu obradu i analizu velikih količina podataka, čime se povećava pouzdanost rezultata i osigurava pravodobno donošenje odluka. Dodatnu vrijednost donosi integracija s umjetnom inteligencijom i metodama strojnog učenja, koja unapređuje sposobnost predviđanja i omogućuje dionicima proaktivno prepoznavanje potencijalnih problema. Također, analiza krivulje kumulativnog napretka omogućava kontinuirano praćenje aktivnosti i pravovremene mjere u slučaju odstupanja od plana.

Integracija analiziranih teorijskih pristupa omogućila je oblikovanje sveobuhvatnog teorijskog okvira čime se zadovoljava prvi pomoćni cilj istraživanja. Teorijski okvir služi kao temelj za razvoj modela predviđanja performansi i ishoda u građevinskim projektima.

3. METODOLOGIJA I MODELIRANJE

U okviru istraživanja provedenog u disertaciji razvija se podsustav za upravljanje modelima, predviđen kao dio šireg sustava za podršku odlučivanju. Slika 10 prikazuje sveobuhvatnu metodologiju istraživanja te ilustrira ključne faze istraživačkog procesa i njihovu međusobnu povezanost.

Metodologija se temelji na teorijskim uvidima i analizi prikupljenih podataka. Cilj je osigurati sustavan pristup razvoju i evaluaciji modela za predviđanje performansi i ishoda građevinskih projekata. Istraživanje započinje pregledom relevantne literature (poglavlje 2.) kojim se identificiraju glavni izazovi u upravljanju građevinskim projektima, analiziraju postojeći pristupi evaluaciji projektne uspješnosti te definiraju temeljni koncepti koji čine teorijski okvir i osnovu za nastavak istraživanja.


Sljedeća faza obuhvaća prikupljanje baza podataka iz realiziranih građevinskih projekata, što omogućuje analizu (kvalitativnu i kvantitativnu) i testiranje razvijenih hipoteza. Na tim temeljima razvija se evaluacijski okvir za predviđanje performansi i ishoda građevinskih projekata (potpoglavlje 3.1.), koji uključuje perspektive ključnih dionika, jasno definirana područja performansi i razvijenu bazu podataka.

Istraživanje se dalje fokusira na razvoj modela za predviđanje prekoračenja ugovorenog trajanja i iznosa (potpoglavlje 3.2.). Ovi modeli razvijaju se primjenom neuronskih mreža i uzimaju u obzir različite perspektive ključnih dionika te kvantitativno definirane kriterije uspjeha. U model se, u svrhu optimizacije, uključuju samo one ulazne podatke koji imaju najveći utjecaj na ishod predviđanja.

Potpoglavlje 3.3. usmjereno je na analizu dinamike projekta kroz razvoj modela za predviđanje kumulativne krivulje napretka. U ovoj fazi uspoređuju se ranije razvijeni matematički modeli iz literature s novim modelom temeljenim na neuronskoj mreži. Razvijeni model integrira rezultate predviđanja prekoračenja ugovorenog trajanja i iznosa iz potpoglavlja 3.2. zajedno s dodatnim ulaznim podacima. Na kraju se pristupi međusobno uspoređuju kako bi se odabrao model s najvećom točnošću predviđanja.

U potpoglavlju 3.4. prikazuje se proces evaluacije, vizualizacije i validacije razvijenih modela, s naglaskom na korištene mjerne metrike, grafički prikaz rezultata i provedbu unakrsne validacije (s 3 i 5 skupova) kako bi se potvrdila točnost, robusnost i pouzdanost modela.

Konačno, primjena modela i adaptivni ciklus (potpoglavlje 3.5.) prikazuju kako se modeli predviđanja implementiraju u proces donošenja odluka. Ta faza omogućuje kontinuirano unapređenje predviđanja i donošenje informiranih odluka u realnom vremenu, čime se zatvara istraživački ciklus i doprinosi postizanju boljih ishoda projekta.



Slika 10. Metodologija istraživanja

3.1. Razvoj evaluacijskog okvira za predviđanje performansi i ishoda građevinskih projekata

Na temelju prethodnih spoznaja razvijen je teorijski okvir (vidi potpoglavlje 2.9.) koji omogućuje dublje razumijevanje međuodnosa između ključnih područja performansi i krajnjih ishoda građevinskih projekata, uvide ključnih dionika te podatke iz realiziranih projekata (Galjanić i dr., 2023). Kao praktična primjena razvijenog teorijskog okvira oblikuje se evaluacijski okvir za predviđanje performansi i ishoda građevinskih projekata, koji omogućuje sustavno praćenje i vrednovanje njihove uspješnosti. Integrirajući različite perspektive ključnih dionika, okvir pruža osnovu za evaluaciju i donošenje informiranih odluka usmjerenih na ostvarenje ciljanih performansi i ishoda građevinskih projekata. Njegov razvoj i validacija opisuju se u narednim potpoglavljima.


3.1.1. Proces razvoja evaluacijskog okvira

U suvremenoj građevinskoj industriji učinkovito mjerenje i predviđanje performansi ključno je za osiguranje uspjeha projekta. S obzirom na složenost i dinamičnost građevinskih projekata, javlja se potreba za jasno definiranim procesima koji omogućuju strukturirano praćenje i procjenu performansi. Kako bi se odgovorilo na ovu potrebu, razvija se sveobuhvatan proces razvoja evaluacijskog okvira (slika 11) koji integrira teorijska znanja, uvide dionika i podatke iz prakse.

Temelji se postavlja kroz sustavan pregled literature, uključujući kritički i tematski pregled, a rezultira definiranjem područja performansi ključnih u postizanju uspjeha građevinskog projekta. Slijedi razvoj evaluacijskog okvira za predviđanje performansi i ishoda građevinskih projekata. Identifikacijom ključnih dionika (vidi potpoglavlje 2.3.3.) i definiranjem ključnih kriterija uspjeha unutar svakog područja performansi oblikuje se hijerarhijska struktura ciljeva.


Slika 12 prikazuje glavne elemente hijerarhijske strukture ciljeva za praćenje i evaluaciju uspješnosti projekta. Ova struktura omogućava analizu uspješnosti kroz jasno definirane razine evaluacije. Na najvišoj razini definira se strateški cilj, odnosno postizanje uspjeha građevinskog projekta kroz sustavno praćenje ključnih područja performansi, uz uvažavanje različitih perspektiva dionika (vidi potpoglavlje 2.4.). Druga razina obuhvaća ključna područja performansi koja predstavljaju temeljne kategorije po kojima se strukturira i prati uspješnost projekta (vidi potpoglavlje 2.5.). Tek tijekom razvoja kvantitativnog modela (vidi potpoglavlje 3.2.1.) uvode se i definiraju treća i četvrta razina. Treća razina sastoji se od kriterija uspjeha koji operacionaliziraju svako ključno područje performansi. Kriteriji se definiraju na temelju pregleda relevantne literature i postojećih istraživanja, čime se osigurava objektivnost evaluacije. Četvrtu

razinu čine ključni pokazatelji uspješnosti koji omogućuju kvantitativnu procjenu ostvarenja pojedinih kriterija.



Slika 11. Proces razvoja evaluacijskog okvira za predviđanje performansi i ishoda građevinskih projekata

Paralelno se izrađuje baza podataka (vidi potpoglavlje 3.1.2.) prikupljanjem podataka kroz polustrukturirane intervjue, primjenu Likertove ljestvice i analizu projektnih dokumenata. Baza podataka omogućava kvantitativnu potvrdu definirane strukture performansi. S obzirom na promjenjive uvjete i neizvjesnost u građevinskim projektima, cijeli proces razvija se iterativno, s mogućnošću prilagodbi na temelju povratnih informacija iz prakse. Iterativni pristup omogućuje kvantitativna podešavanja temeljena na objektivnim podatcima (npr. mjerenje troškova i vremena) i kvalitativna podešavanja temeljena na analizama stavova ključnih dionika.



Slika 12. Razvoj hijerarhijske struktura ciljeva za praćenje i evaluaciju uspješnosti projekta

Proces razvoja evaluacijskog okvira temelji se na kombinaciji kvalitativnih metoda (analiza literature, polustrukturirani intervjui) i kvantitativnih metoda (analiza podataka, usporedba ugovorenih i realiziranih trajanja i iznosa primjenom MacDonalдове jednadžbe (2002), Likertova ljestvica). Kombinacija pristupa omogućuje sveobuhvatan pregled i praćenje uspješnosti projekta, dok istovremeno pruža dublji uvid u percepciju i izazove s kojima se suočavaju ključni dionici te potiče kontinuirano unapređenje.

Razvijeni evaluacijski okvir omogućava identifikaciju i rangiranje ključnih područja performansi s najvećim utjecajem na konačne ishode projekta. Osim što osigurava objektivnu analizu, pristup potiče suradnju dionika i donošenje informiranih odluka koje uvažavaju različite interese. Razvijenim procesom ostvaruje se drugi pomoćni cilj istraživanja, odnosno stvaranje postupka koji se može koristiti u okruženju s više dionika za identifikaciju i rangiranje područja performansi ključnih za postizanje uspjeha građevinskih projekata. Ovako navedena primjena kombiniranih metoda omogućuje objektivnu evaluaciju, dok iterativni postupak prilagodbe osigurava fleksibilnost okvira i njegovu primjenu u različitim građevinskim projektima.

3.1.2. Validacija evaluacijskog okvira kroz višestruku studiju slučaja

Kako bi se evaluacijski okvir testirao u stvarnim uvjetima i kako bi se provjerila njegova primjenjivost, a time i postavljenog teorijskog okvira, provodi se višestruka studija slučaja. Istraživački pristup i metodologija temelje se na smjernicama koje je razvio Yin (2018), a cilj je demonstracija empirijske relevantnosti evaluacijskog okvira kroz njegovu primjenu u praksi (Levy, 2008).

Protokol višestruke studije slučaja razvija se kroz tri glavne faze (slika 13):


- (1) Definiranje i dizajn višestruke studije slučaja,
- (2) Priprema, prikupljanje i analiza podataka te
- (3) Zaključci višestruke studije slučaja.

U prvoj fazi provodi se analiza postojeće literature primjenom metoda kao što su sustavno pretraživanje, tematska analiza i kritički pregled literature, čime se postavljaju teorijski temelji i kontekstualizira istraživački okvir. Uz bibliometrijske metode (Pollack i Adler, 2015; Norouzi i dr., 2021) koriste se i kvalitativne metode analize kako bi se osigurala relevantnost kriterija za evaluaciju. Pregledne metode analize (Grant i Booth, 2009) koriste se za razvoj teorije, odabir reprezentativnih slučajeva te oblikovanje protokola za prikupljanje podataka. Odabir slučajeva temelji se na načelu raznolikosti relevantnih dimenzija evaluacijskog okvira (Seawright i Gerring, 2008).

Postavljaju se kriteriji za odabir projekata:

- (1) Projekti moraju biti financirani javnim sredstvima. Kriterij je odabran kako bi se osigurala usporedivost podataka, budući da su javni projekti često podložni sličnim regulatornim, administrativnim i financijskim pravilima. Javne investicije također prolaze kroz strože postupke nabave i izvještavanja, što omogućava bolju dostupnost i pouzdanost podataka.
- (2) Ugovorene vrijednosti trebaju se kretati između 7,5 i 25 milijuna eura. Raspon je odabran kako bi se istraživanje fokusiralo na projekte koji predstavljaju značajne investicije, ali nisu ekstremno veliki projekti s kompleksnim financijskim i političkim utjecajem. Donja granica od 7,5 milijuna eura temelji se na pragovima koji se koriste u određenim EU fondovima, gdje projekti u tom rasponu često ulaze u kategoriju značajnih, ali ne i velikih infrastrukturnih investicija. Gornja granica od 25 milijuna eura određena je na temelju dostupne baze podataka analiziranih projekata te kako bi se isključili projekti s izrazito visokim individualnim utjecajem koji bi mogli značajno odstupati od prosječnih vrijednosti u uzorku te potencijalno narušiti usporedivost analiza.
- (3) Projekti moraju biti ugovoreni od 2016. godine nadalje. Vremenski okvir osigurava relevantnost podataka jer uključuje recentne projekte koji su ugovarani i izvođeni u okviru aktualnih zakonskih, ekonomskih i tehnoloških uvjeta.

Na temelju ovih kriterija odabrano je pet građevinskih projekata koji su analizirani u potpoglavlju 4.1. Nakon odabira slučajeva razvija se protokol za prikupljanje podataka, čime se formira baza podataka (1).



Slika 13. Protokol višestruke studije slučaja

Za prikupljanje podataka koriste se komplementarne metode uključujući analizu projektne dokumentacije (ugovori o gradnji, aneksi ugovora, mjesečna izvješća o planiranim i realiziranim radovima, komunikacija među dionicima, zapisnici o primopredaji), provođenje polustrukturiranih intervjua sa sudionicima projekata te upotrebu Likertove ljestvice i vizualne kategorizacije rezultata. Likertova ljestvica omogućuje kvantifikaciju subjektivne procjene dionika, dok vizualna kategorizacija pruža intuitivan prikaz odstupanja između očekivanih i ostvarenih performansi projekata. Intervjui se provode s ključnim dionicima projekta kako bi se dobile informacije o njihovom iskustvu i percepcijama uspješnosti projekata.


Tijekom polustrukturiranih intervjua sudionici se pozivaju da rangiraju ključna područja performansi prema njihovoj važnosti za postizanje uspjeha projekta. Rangiranje omogućuje identifikaciju razlika u percepcijama među sudionicima i ističe potrebu za usklađivanjem njihovih stavova. U drugom dijelu intervjua sudionici, koristeći Likertovu ljestvicu od 1 do 5, ocjenjuju u kojoj su mjeri pojedina područja performansi uzeta u obzir tijekom izvedbe projekta. Dodatno, koristi se vizualna kategorizacija rezultata, pri čemu su područja označena kao „+“ (zeleno) za potpuno uzeta u obzir, „±“ (žuto) za djelomično uzeta u obzir te „-“ (crveno) za područja koja nisu bila uzeta u obzir. Primjenjena metoda omogućuje usporedbu očekivanih i stvarnih performansi te identifikaciju razlika u percepcijama različitih dionika. Svi rezultati se normaliziraju unutar skupina dionika radi osiguravanja usporedbe unutar i između projekata.

Svaki pojedinačni slučaj detaljno se analizira prema unaprijed definiranom protokolu. Nakon analize studija slučaja povratna petlja omogućuje ažuriranje ili redizajniranje pristupa u slučaju važnih otkrića tijekom proučavanja. Svaki slučaj se detaljno analizira i rezultira pisanjem pojedinačnog izvješća o slučaju. U završnoj fazi provodi se sinteza svih studija slučaja i izrađuje završna analiza koja omogućuje reviziju i doradu razvijene teorije te, ako je potrebno, formulaciju novih implikacija. Pristup omogućuje sveobuhvatno istraživanje i razumijevanje različitih područja performansi. Provedbom višestruke studije slučaja ostvaruje se treći pomoćni cilj istraživanja. Naime, razvijanje i validacija evaluacijskog okvira omogućuje uspostavljanje izravne veze između mjerenja performansi u stvarnim projektima i njihovog kasnijeg predviđanja, čime se dodatno produbljuje razumijevanje odnosa između ključnih područja performansi i projektnih ishoda. Rezultati (vidi potpoglavlje 4.1.) omogućuju uvid u percepcije dionika o ključnim područjima performansi te služe kao temelj za daljnji razvoj modela predviđanja prekoračenja ugovorenog trajanja i iznosa.

3.2. Razvoj modela predviđanja prekoračenja ugovorenog trajanja i iznosa

Kako bi se unaprijedila točnost predviđanja prekoračenja ugovorenog trajanja i iznosa, razvijaju se modeli koji na temelju trenutnih performansi omogućuju identifikaciju i predviđanje odstupanja. Uz postojeće podatke prikupljene kroz višestruku studiju slučaja, uzorak se proširuje dodatnim podacima iz sedam realiziranih građevinskih projekata s područja različitih dijelova Hrvatske, čime se formira baza podataka (2). Time broj analiziranih projekata doseže dvanaest i osigurava veću raznolikost ulaznih primjera za treniranje neuronske mreže. Nadalje, kako bi se povećala količina podataka, svaki projekt se analizira u tri vremenske točke koje približno odgovaraju prvoj, drugoj i trećoj trećini ukupnog trajanja projekta. Ukupni broj ulaznih podataka povećava se na 36 primjera, čime su stvoreni uvjeti za efikasnije treniranje neuronske mreže. Za svaki projekt prikupljaju se ključni dokumenti (ugovori o gradnji, aneksi ugovora, mjesečna izvješća o planiranim i realiziranim radovima, službena komunikacija između ključnih dionika i zapisnici o primopredaji). Uz analizu projektne dokumentacije, provode se i polustrukturirani intervjui sa sudionicima projekata kako bi se prikupili svi relevantni podatci za definiranje ulaznih varijabli modela i njihovu evaluaciju u okviru neuronske mreže.

Proces razvoja modela prikazuje se na slici 14 i objašnjava u nastavku, a cjelokupni kod korišten za razvoj modela predviđanja prekoračenja ugovorenog trajanja i iznosa, uključujući sve korake opisane u nastavku, dostupan je u prilogu A.



Slika 14. Proces razvoja modela predviđanja prekoračenja ugovorenog trajanja i iznosa

3.2.1. Prikupljanje i priprema podataka za neuronsku mrežu

Pri razvoju modela neuronske mreže, od ključne je važnosti odabrati relevantne ulazne varijable. Kvaliteta ulaznih podataka značajno utječe na točnost i pouzdanost predviđanja. U ovom istraživanju, ulazni podatci obuhvaćaju kvantificirane informacije o područjima performansi. Kvantifikacija se temelji na kombinaciji subjektivnih procjena sudionika (evaluacijske skale) i objektivnih projektnih podataka. Područja performansi (kvaliteta, vrijeme, trošak, sigurnost, produktivnost, zadovoljstvo sudionika i zadovoljstvo investitora) međusobno su povezana, a njihova evaluacija pruža sveobuhvatan uvid u cjelokupnu izvedbu projekta. Svako područje performansi operacionalizira se kroz pripadajuće ključne faktore uspjeha, a ti se faktori dalje razlažu na mjerljive pokazatelje uspješnosti koji čine ulazne varijable modela. U kontekstu modela neuronske mreže, ključni pokazatelji uspješnosti predstavljaju ulazne podatke odnosno značajke (engl. feature) koje mreža koristi za daljnje predviđanje. U daljnjem tekstu za ključne pokazatelje uspješnosti koristi se izraz značajke. Njihovo definiranje prema SMART principima osigurava konzistentnost i pouzdanost podataka u procesu treniranja modela. Odabir kriterija temelji se na kombinaciji pregleda literature, iskustava iz provedenih studija slučaja i mišljenja stručnjaka, čime se osigurava metodološka utemeljenost modela.

Za potrebe modeliranja definira se ukupno 16 značajki (3 kategorijske i 13 numeričkih). Kategorijske značajke obuhvaćaju sljedeće:

- (1) Tip projekta. Podatci se klasificiraju prema tipu građevinskih projekata na komunalnu infrastrukturu, cestovnu infrastrukturu i visokogradnju. Odabrana klasifikacija temelji se na literaturi gdje Kaka i Price (1991) u svojem istraživanju dijele projekte na visokogradnju i cestovnu infrastrukturu, dok Danilina i Chebotarev (2017) dijele projekte na cestovnu i komunalnu infrastrukturu. U ovom istraživanju objedinjuju se sve tri kategorije kako bi se pružila sveobuhvatnija analiza i pružila šira perspektiva na specifičnosti građevinskih projekata.
- (2) Vrsta ugovora. Definiraju se tri kategorije ugovornih modela: klasični ugovor o gradnji, FIDIC ugovor i ugovor po principu „ključ u ruke“, budući da se rizici i odgovornosti dionika značajno razlikuju ovisno o vrsti ugovora.
- (3) Faza projekta. Svaki projekt promatra se kroz tri vremenske točke: prva, druga i treća trećina ukupnog trajanja projekta, kako bi se obuhvatila dinamika projekta tijekom cijele faze izvođenja radova.

Numeričke značajke obuhvaćaju ugovorenu vrijednost radova, kvalitetu projektne dokumentacije, upravljanje promjenama, analizu dinamičkog plana, pridržavanje rokova aktivnosti, omjer troškova, trend promjena i dodatnih radova, identifikaciju

opasnosti, stopu nezgoda, fluktuaciju zaposlenika, upravljanje sukobima, zadovoljstvo sudionika i zadovoljstvo investitora stručnošću izvođača.

Podatci se prikupljaju prema strukturi prikazanoj u tablici 13, dok su kriteriji i način ocjenjivanja prikazani u tablici 14, uključujući korištene izraze i kvalitativne skale. Podaci se prikupljaju putem intervjua s predstavnicima izvođača, budući da oni raspolažu većinom relevantnih informacija iz projektne dokumentacije. Za značajke koje se vrednuju kvalitativnim skalama i koje nije moguće kvantificirati isključivo na temelju dokumentacije (upravljanje promjenama, pridržavanje rokova aktivnosti, identifikacija opasnosti, fluktuacija zaposlenika, upravljanje sukobima, zadovoljstvo sudionika i zadovoljstvo investitora stručnošću izvođača), dodatno se prikupljaju procjene ostalih dionika putem intervjua i/ili anketnih upitnika. Za svaki projekt ocjene daju predstavnici ključnih dionika, pri čemu se ne primjenjuju težine po skupinama. Konačne ocjene računaju se kao aritmetička sredina odgovora po projektu i vremenskoj fazi, a rezultati se zaokružuju na najbliži cijeli broj. Definirani pristup omogućuje sintezu različitih perspektiva dionika, uz smanjenje utjecaja pojedinačnih ekstrema u ocjenama. U fazi izrade modela koriste se podatci iz već završenih projekata, što omogućuje procjenu stvarnih vrijednosti prekoračenja ugovorenog trajanja i iznosa. Izlazne varijable definiraju se kao relativne vrijednosti pomoću sljedećih izraza:

$$PI = \frac{(\text{naplaćeni iznos} - \text{ugovoreni iznos})}{\text{ugovoreni iznos}} \quad (1)$$

$$PT = \frac{(\text{stvarno trajanje} - \text{ugovoreno trajanje})}{\text{ugovoreno trajanje}} \quad (2)$$

gdje je *PI* postotak prekoračenja ugovorenog iznosa po završetku izvođenja radova, a *PT* postotak prekoračenja ugovorenog trajanja projekta po završetku izvođenja radova.

Tablica 13. Struktura podataka korištenih u istraživanju

P_i	T_i	V_i	F_f	U_i	K_i	$UP_{i,f}$	$AD_{i,f}$	$PR_{i,f}$	$OT_{i,f}$	$TR_{i,f}$	$IO_{i,f}$	$SN_{i,f}$	$FZ_{i,f}$	$US_{i,f}$	$ZS_{i,f}$	$ZI_{i,f}$	PI_i	PT_i
$P_{1,j}$	T_1	V_1	F_j	U_1	$K_{1,j}$	$UP_{1,j}$	$AD_{1,j}$	$PR_{1,j}$	$OT_{1,j}$	$TR_{1,j}$	$IO_{1,j}$	$SN_{1,j}$	$FZ_{1,j}$	$US_{1,j}$	$ZS_{1,j}$	$ZI_{1,j}$	PI_1	PT_1
$P_{1,k}$	T_1	V_1	F_k	U_1	$K_{1,k}$	$UP_{1,k}$	$AD_{1,k}$	$PR_{1,k}$	$OT_{1,k}$	$TR_{1,k}$	$IO_{1,k}$	$SN_{1,k}$	$FZ_{1,k}$	$US_{1,k}$	$ZS_{1,k}$	$ZI_{1,k}$	PI_1	PT_1
$P_{1,z}$	T_1	V_1	F_z	U_1	$K_{1,z}$	$UP_{1,z}$	$AD_{1,z}$	$PR_{1,z}$	$OT_{1,z}$	$TR_{1,z}$	$IO_{1,z}$	$SN_{1,z}$	$FZ_{1,z}$	$US_{1,z}$	$ZS_{1,z}$	$ZI_{1,z}$	PI_1	PT_1
$P_{2,j}$	T_2	V_2	F_j	U_2	$K_{2,j}$	$UP_{2,j}$	$AD_{2,j}$	$PR_{2,j}$	$OT_{2,j}$	$TR_{2,j}$	$IO_{2,j}$	$SN_{2,j}$	$FZ_{2,j}$	$US_{2,j}$	$ZS_{2,j}$	$ZI_{2,j}$	PI_2	PT_2
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
$P_{n,z}$	T_n	V_n	F_z	U_n	$K_{n,z}$	$UP_{n,z}$	$AD_{n,z}$	$PR_{n,z}$	$OT_{n,z}$	$TR_{n,z}$	$IO_{n,z}$	$SN_{n,z}$	$FZ_{n,z}$	$US_{n,z}$	$ZS_{n,z}$	$ZI_{n,z}$	PI_n	PT_n

gdje je:

P_i – Identifikator projekta i s fazom f
 T_i – Tip projekta
 V_i – Vrsta ugovora
 F_i – Faza projekta gdje je $f \in \{j, k, z\}$
 U_i – Ugovorena vrijednost radova
 K_i – Kvaliteta projektne dokumentacije
 UP_i – Upravljanje promjenama
 AD_i – Analiza dinamičkog plana
 PR_i – Pridržavanje rokova aktivnosti
 OT_i – Omjer troškova

TR_i – Trend promjena i dodatnih radova
 IO_i – Identifikacija opasnosti
 SN_i – Stopa nezgoda
 FZ_i – Fluktuacija zaposlenika
 US_i – Upravljanje sukobima
 ZS_i – Zadovoljstvo sudionika
 ZI_i – Zadovoljstvo investitora stručnošću izvođača
 PI – Postotak prekoračenja ugovorenog iznosa po završetku izvođenja radova
 PT – Postotak prekoračenja ugovorenog trajanja po završetku izvođenja radova

Tablica 14. Kriteriji uspjeha građevinskih projekata

KPI	Naziv kriterija	Način i opis ocjenjivanja
T _i	Tip projekta	Kriterij definira tip projekta: komunalna infrastruktura, cestovna infrastruktura ili visokogradnja.
V _i	Vrsta ugovora	Ugovor se klasificira prema njegovoj vrsti: standardni ugovor o gradnji, FIDIC ugovor ili ugovor po principu „ključ u ruke“.
F _i	Faza projekta	Označava fazu u kojoj se projekt nalazi u trenutku prikupljanja podataka: prva, druga ili treća trećina ukupnog trajanja.
U _i	Ugovorena vrijednost radova	Upisuje se početna, ugovorena vrijednost radova u eurima.
K _i	Kvaliteta projektne dokumentacije	Izražava se kao omjer ukupno naplaćenih dodatnih, vanstroškovničkih i nepredviđenih radova u odnosu na stvarno izvedene radove u promatranoj fazi.
UP _i	Upravljanje promjenama	Procjenjuje se postojanje i učinkovitost sustava za evidentiranje izmjena i dodatnih radova, na skali od 1 do 5: (1) Sustav ne postoji, promjene se ne prate ni ne dokumentiraju. (2) Sustav ne postoji, dio izmjena je ipak službeno evidentiran. (3) Sustav postoji ali nije adekvatno razrađen, većina promjena je službeno evidentirana. (4) Sustav postoji i bilježi sve ključne informacije, uz manje nedostatke. (5) Sustav je potpun, jasno definiran i omogućuje transparentno praćenje svih izmjena.
AD _i	Analiza dinamičkog plana	Mjeri se odstupanje od planirane dinamike izvođenja radova. Izračunava se kao omjer razlike između realiziranog i planiranog iznosa radova u odnosu na planirani iznos.
PR _i	Pridržavanje rokova aktivnosti	Procjenjuje se učinak kašnjenja u dostavi dokumentacije i nužnih dodatnih informacija na dinamiku projekta, na skali od 1 do 5: (1) Značajna kašnjenja ozbiljno ugrožavaju kritični put, nemoguće je dovršiti radove u ugovorenom roku. (2) Značajna kašnjenja ugrožavaju kritični put, ali postoji mogućnost dovršetka radova u ugovornom roku.

		(3) Kašnjenje ne ugrožava kritični put, ali predstavlja potencijalni rizik. (4) Manja kašnjenja, nema prijetnje realizaciji dinamičkog plana. (5) Dostava je u potpunosti pravovremena i usklađena s planom.
OT _i	Omjer troškova	Kriterij pokazuje razinu odstupanja od financijskog plana. Prikazuje se odnos između realiziranog iznosa radova i početno ugovorene vrijednosti.
TR _i	Trend promjena i dodatnih radova	Kriterij se izražava kao omjer ukupno naplaćenih dodatnih, vanstroškovničkih i nepredviđenih radova prema ukupno ugovorenoj vrijednosti projekta.
IO _i	Identifikacija opasnosti	Procjenjuje se učestalost i ozbiljnost sigurnosnih prijedloga te angažman koordinatora zaštite na radu na skali 1 do 3: (1) Koordinator ne sudjeluje ili sudionici odbijaju poboljšanja sigurnosti; više od 7 sugestija tjedno za poboljšanje sigurnosti. (2) Koordinator je umjereno zadovoljan primjenom sigurnosnih propisa; 3-7 sugestija tjedno za poboljšanje sigurnosti. (3) Koordinator je zadovoljan primjenom propisa; do 2 sugestije tjedno za poboljšanje sigurnosti.
SN _i	Stopa nezgoda	Pokazatelj sigurnosti na gradilištu. Izračunava se kao: $1000 \times (\text{Broj prijavljenih nesreća}) / (\text{Ukupan broj radnih sati svih radnika na projektu})$
FZ _i	Fluktuacija zaposlenika	Kriterij mjeri razinu promjena u sastavu projektnog tima i njihov utjecaj na timsku stabilnost na skali 1 do 5: (1) Više od 20 % tima ili ključni članovi napustili su projekt, zapošljavanje novih članova izostaje, što značajno narušava stabilnost tima. (2) 10-20 % tima je napustilo projekt. Dolazak novih članova je ograničen što zahtijeva dodatne napore u održavanju stabilnosti tima. (3) Do 10 % članova tima napustilo je ili se pridružilo projektu, što ukazuje na stabilnost i kontinuitet u izvršavanju radnih zadataka. (4) Timu su se pridružili novi članovi, povećanje tima za 10-20 % što pridonosi raznolikosti tima i može poboljšati kvalitetu rada. (5) Tim je proširen za više od 20 % ili su se pridružili

		članovi izuzetno visoke stručnosti, što značajno unapređuje kapacitete i kvalitetu rada tima.
US _i	Upravljanje sukobima	Procjenjuje se način prepoznavanja i rješavanja sukoba unutar tima na skali 1 do 5: (1) Sukobi se ne rješavaju, radna atmosfera izrazito negativna. (2) Sukobi su prisutni i loše rješavani, povremeno narušavaju produktivnost. (3) Sukobi se ponekad konstruktivno rješavaju, ali postoje periodi napetosti. (4) Većina sukoba rješava se uspješno, uz pozitivan utjecaj na radnu atmosferu i suradnju u timu. (5) Sukobi se brzo prepoznaju i rješavaju na konstruktivan način, što doprinosi produktivnoj radnoj atmosferi u timu.
ZS _i	Zadovoljstvo sudionika	Kriterij procjenjuje atmosferu i suradnju među projektnim sudionicima na skali 1 do 5: (1) Izrazito loša atmosfera, niska razina povjerenja, česti sukobi i komunikacijski problemi. (2) Suradnja je nesigurna i povremeno problematična, komunikacija je često nejasna. (3) Odnosi su korektni, povremeni nesporazumi otežavaju rad. (4) Suradnja je učinkovita, a komunikacija pravovremena, uz rijetke prepreke. (5) Atmosfera je pozitivna, povjerenje potpuno, suradnja besprijekorna.
ZI _i	Zadovoljstvo investitora stručnošću izvođača	Kriterij procjenjuje investitorovu percepciju o znanju i stručnosti izvođača na skali 1 do 5: (1) Ozbiljan nedostatak stručnosti dovodi do loše izvedbe i učestalih grešaka. (2) Osnovne vještine prisutne, ali iskustvo i znanje su ograničeni. (3) Stručnost je zadovoljavajuća, no postoji prostor za poboljšanje. (4) Visoka razina stručnosti omogućuje kvalitetnu i pouzdanu izvedbu. (5) Izvođač je iznimno stručan, iskusan i rješava probleme s visokom profesionalnošću.

Modeli predviđanja prekoračenja ugovorenog trajanja i iznosa se razvijaju unutar Jupyter Notebooka 7.3.2. Njegova modularnost omogućuje integraciju koda, rezultata i interpretacije u jedinstveni format. Korištenje ovog alata omogućuje postupnu izgradnju i testiranje modela uz vizualizaciju rezultata. Na početku izrade modela kreira se okruženje koje osigurava potpunu reproducibilnost rezultata, uključujući fiksiranje početnog sjemena (engl. seed) kako bi se omogućio deterministički način rada.

Podatci se prikupljaju i pohranjuju u Excel datoteku, uz provjeru ispravnosti unosa radi osiguravanja dosljednog formata i sadržaja u skladu s definiranim strukturama podataka. Nakon učitavanja podataka u Python, podatci se obrađuju i pripremaju, uključujući kodiranje kategorijskih varijabli i standardizaciju numeričkih varijabli. Budući da podatci uključuju tri kategorijske varijable, primijenjuje se „One-Hot Encoding“ metoda koja pretvara kategorijske varijable u niz binarnih varijabli. Svaka potkategorija postaje poseban stupac, pri čemu vrijednost 1 označava njezinu prisutnost u retku, a vrijednost 0 odsutnost. Nakon primjene metode enkodiranja, početne tri kategorijske varijable proširuju se na ukupno devet numeričkih varijabli. Sljedeći korak je standardizacija numeričkih varijabli pomoću „StandardScaler“. Primjenjuje se na varijable koje su izvorno numeričke jer standardizacija nije ni potrebna ni korisna za enkodirane varijable. Numeričke varijable transformiraju se tako da imaju srednju vrijednost 0 i standardnu devijaciju 1. Ovaj postupak osigurava ujednačenost među varijablama različitih jedinica mjere i sprječava da one s većim rasponima neproporcionalno utječu na model.

3.2.2. Odabir ulaznih podataka za neuronsku mrežu

Prikupljeni i obrađeni podatci, koji se koriste kao ulazni podatci za istraživanje, prikazuju se u prilogu B. Iako su prikupljeni svi potencijalno korisni podatci, cilj je smanjenje broja značajki kako bi se u praksi omogućilo inženjerima da brzo prikupe samo najvažnije informacije te uz minimalan napor postignu validne rezultate. Smanjenjem broja značajki model postaje jednostavniji, treniranje brže, a generalizacija pouzdanija, osobito kada se raspolaze manjim skupovima podataka osjetljivim na šum. Kako bi se osiguralo da model koristi samo najrelevantnije značajke, provodi se analiza važnosti značajki primjenom algoritma slučajne šume. Koristi se algoritam sa 100 stabala odlučivanja. Relativna važnost značajki procjenjuje se na temelju njenog doprinosa smanjenju ukupne pogreške unutar stabala. Svako stablo modelira različite podskupove podataka, a za svaku značajku računa se koliko doprinosi smanjenju pogreške na pojedinim čvorovima. Konačna važnost određuje se kao normalizirani zbroj svih doprinosa značajke kroz cijelu šumu stabala. Značajke s višim vrijednostima važnosti imaju veći utjecaj na predviđanje ciljne varijable. Opisani

pristup omogućuje jasno rangiranje značajki i pomaže u identifikaciji najvažnijih značajki koje treba uključiti u konačni model.

Model se evaluira na različitim kombinacijama podskupova značajki i različitim arhitekturama neuronske mreže kako bi se odredila optimalna kombinacija. Postupak započinje s tri najvažnije značajke, a broj se postupno povećava sve do uključivanja cijelog skupa značajki. Takav pristup omogućuje pronalaženje ravnoteže između jednostavnosti modela i njegove točnosti predviđanja.

Zbog ograničene veličine skupa podataka postoji povećan rizik od prekomjernog prilagođavanja, što može negativno utjecati na sposobnost modela da generalizira na nove, nepoznate podatke. Kako bi se rizik smanjio i poboljšala generalizacija modela, arhitektura mreže i pripadajući hiperparametri optimiziraju se primjenom unakrsne validacije u tri skupa (engl. 3-fold cross-validation). Time se omogućuje bolja procjena stabilnosti modela i smanjuje pristranost prema određenom podskupu podataka. Svaki podskup podataka naizmjenično se koristi za testiranje, dok se preostala dva koriste za treniranje, čime se povećava robusnost i pouzdanost modela.

Optimizacija hiperparametara i arhitekture mreže provodi se primjenom metode slučajnog pretraživanja. Iako metoda slučajnog pretraživanja može propustiti neke optimalne kombinacije i nije tako sistematična kao metoda pretraživanja mreže, dovoljno je učinkovita za inicijalnu optimizaciju modela. Njena prednost leži u sposobnosti da u kraćem vremenskom razdoblju pronađe kvalitetna rješenja, osobito kada je raspon mogućih vrijednosti hiperparametara širok. Tijekom optimizacije modela testiraju se različite kombinacije arhitekture i hiperparametara. Testiraju se modeli s jednim i dva skrivena sloja, dok se broj neurona po sloju kreće od 8 do 40 u koracima od četiri. U ovom slučaju dodavanje trećeg skrivenog sloja ne donosi značajno poboljšanje, već povećava rizik od prekomjernog prilagođavanja. Ispuštanje neurona, koje se koristi kao tehnika regularizacije za smanjenje prekomjernog prilagođavanja, ispituje se u rasponu od 0 % do 30 % s korakom od 10 %. Dodatno, testiraju se tri različite aktivacijske funkcije (ReLU, tanh i sigmoid), a stopa učenja varira između vrijednosti 0,01, 0,005 i 0,001. Za inicijalnu optimizaciju odabire se Adam optimizator jer je najpopularniji i učinkovit za širok spektar modela. U skladu s prirodom regresijskog problema, u izlaznom sloju koristi se linearna aktivacijska funkcija. Za funkciju pogreške koristi se srednja kvadratna pogreška (engl. Mean Squared Error, MSE), standardni izbor za regresijske zadatke, zato što penalizira veće pogreške u predviđanjima i pomaže u preciznom usklađivanju modela s ciljnim varijablama. Nasumično se testiraju različite kombinacije modela. Broj iteracija optimizacije postavlja se na 30, čime se osigurava brže izvođenje postupka. S obzirom da optimizacija uključuje i 20 različitih kombinacija značajki, ukupno se ispituje 600 različitih kombinacija arhitekture neuronske mreže i pripadajućih hiperparametara kroz iterativni proces optimizacije.

Za svaku kombinaciju značajki izabire se optimalan model na temelju funkcije gubitka, a podatci o njegovoj arhitekturi, hiperparametrima i pripadajućim metrikama spremaju se u Excel što omogućuje daljnju analizu i identifikaciju globalno optimalnog modela. Osim toga, arhitektura, pripadajuće težine i hiperparametri testiranih modela spremaju se u JSON i Keras formatu, čime se omogućava ponovno učitavanje i primjena modela. Optimalan model odabire se na temelju analize metrika točnosti.

Za odabranu arhitekturu izrađuje se model neuronske mreže. Model se trenira na podacima podijeljenima u skup za treniranje (80 %) i skup za testiranje (20 %). Takva podjela omogućuje evaluaciju modela na neviđenim podacima i time pruža realističniju procjenu njegove učinkovitosti. Zbog ograničene veličine baze podataka, dodatni validacijski skup nije uključen. Sadržavao bi svega šest primjera, što nije dovoljno za pouzdanu procjenu. Izrađuje se vizualizacija krivulje gubitka kroz epohe i usporedba stvarnih i predviđenih vrijednosti, što omogućuje detaljno praćenje napretka modela (za detaljniji opis evaluacije i vizualizacije modela vidi potpoglavlje 3.4.).

3.2.3. Dodatna optimizacija izabranog modela

U skladu s procesom razvoja modela predviđanja prekoračenja ugovorenog trajanja i iznosa (slika 14), sljedeća faza razvoja uključuje procjenu ravnoteže ciljne varijable, pri čemu se dodatno analiziraju distribucija i potencijalna potreba za korekcijom neuravnoteženosti. Ako rezultati inicijalne optimizacije pokažu izraženu neuravnoteženost distribucije ciljne varijable, što može ograničiti sposobnost neuronske mreže za generalizaciju na nove podatke, primjenjuje se tehnika SMOGN. Navedena metoda generira sintetičke podatke interpolacijom između postojećih vrijednosti koristeći k-najbliže susjede, a zatim dodaje Gaussovu buku kako bi se poboljšala reprezentativnost podataka i povećala točnost predviđanja.

Nakon procjene ravnoteže ciljne varijable i eventualne primjene SMOGN, nastavlja se proces dodatne optimizacije (engl. fine-tuning) s ciljem daljnjeg unaprjeđenja performansi modela. Iz inicijalne optimizacije zadržava se odabrana arhitektura mreže (broj skrivenih slojeva, neurona i pripadajuće težine) te broj značajki, dok su hiperparametri podvrgnuti detaljnijoj optimizaciji. U ovoj fazi koristi se metoda pretraživanja mreže koja sustavno testira sve moguće kombinacije hiperparametara u manjem i fokusiranijem rasponu. Testirane kombinacije uključuju aktivacijske funkcije ReLU, LeakyReLU, elu, sigmoid i tanh te optimizatore Adam, RMSprop i SGD. Budući da se primjenom SGD optimizatora dodatno ispituje utjecaj momenta, testiraju se vrijednosti momenta 0,9, 0,7, 0,5, 0,3, 0,05 i 0. Uz to, ispuštanje neurona analizira se u rasponu od 0 % do 30 % s koracima od 5 %, a stopa učenja za vrijednosti 0,001, 0,003, 0,005 i 0,01. Za svaki model predviđanja ispituje se 1120 različitih kombinacija

hiperparametara. Napredak modela analizira se usporedbom novih rezultata s prethodnim. Kao funkcija gubitka koristi se MSE, što omogućuje preliminarni odabir najuspješnijih modela.

Svi trenirani modeli, zajedno s arhitekturom, pripadajućim težinama i hiperparametrima, pohranjuju se u JSON i Keras formatu kako bi se omogućilo njihovo ponovno učitavanje i daljnja primjena. Konačni odabir optimalnog modela temelji se na detaljnoj analizi više evaluacijskih metrika (navedenih u potpoglavlju 3.4.).

Razvojem i validacijom modela (vidi potpoglavlje 3.4.) za predviđanje prekoračenja ugovorenog trajanja i iznosa primjenom neuronskih mreža, ostvaruje se četvrti pomoćni cilj istraživanja. Identifikacija najvažnijih značajki putem algoritma slučajne šume te optimizacija arhitekture i hiperparametara omogućuju precizna predviđanja uz smanjenje broja potrebnih ulaznih podataka. Time se, u skladu s ciljem, omogućuje praktična primjena modela uz smanjeni broj značajki, optimizira proces prikupljanja podataka i povećava učinkovitost u realnim projektnim uvjetima, bez kompromisa u točnosti predviđanja.

U nastavku se prikazuje razvoj modela predviđanja krivulje kumulativnog napretka, pri čemu se uspoređuju točnost i prilagodljivost tradicionalnih modela i modela razvijenog korištenjem neuronske mreže.

3.3. Razvoj i odabir modela predviđanja krivulje kumulativnog napretka projekta


Proces razvoja i odabira modela predviđanja krivulje kumulativnog napretka (slika 15) temelji se na usporedbi dva pristupa, postojećih matematičkih modela i modela predviđanja razvijenog primjenom neuronske mreže. S obzirom na varijabilnost dinamike građevinskih projekata, cilj analize je utvrditi koji pristup omogućuje preciznije predviđanje dinamike financijskog i vremenskog napretka građevinskih projekata.

U svrhu razvoja modela prikupljaju se podatci koji obuhvaćaju ugovorene i realizirane iznose, planirano i stvarno trajanje projekata, vrijednosti mjesečnih i okončanih situacija te informacije o tipu projekta, pri čemu se razlikuju visokogradnja, komunalna i cestovna infrastruktura. Kako bi se osigurala usporedivost podataka, primijenjuje se normalizacija svih numeričkih značajki, čime se podatci dovode u isti raspon vrijednosti. Normalizacija omogućuje usporedivost podataka i sprječava dominaciju varijabli s većim apsolutnim vrijednostima. Za normalizaciju vremena primijenjuje se pristup u kojem je početak projekta predstavljen s 0 %, dok svaka mjesečna situacija prikazuje postotni udio proteklog vremena u odnosu na ukupno trajanje projekta. Isti postupak koristi se za normalizaciju naplaćenog iznosa, pri čemu je početni iznos

predstavljen s 0 %, a svaka mjesečna situacija prikazuje postotni udio naplaćenog iznosa u odnosu na ukupni naplaćeni iznos definiran okončanom situacijom. Model predviđa dinamiku kumulativnog napretka projekta analizirajući distribuciju naplaćenog iznosa u funkciji normaliziranog vremenskog okvira.

Nakon pripreme podataka, razvijaju se matematički modeli (vidi potpoglavlje 3.3.1.) te se paralelno razvija model neuronske mreže (vidi potpoglavlje 3.3.2.).

U završnom koraku ove istraživačke faze provodi se usporedba performansi modela korištenjem metrika točnosti. Na temelju analize dobivenih rezultata identificira se optimalan model koji postiže najveću točnost u predviđanju krivulje kumulativnog napretka projekta.



Slika 15. Proces razvoja i odabira modela predviđanja krivulje kumulativnog napretka projekta

3.3.1. Matematički modeli

Na temelju pregleda literature o krivuljama kumulativnog napretka i postojećim matematičkim modelima, identificiraju se modeli koji su odabrani za daljnju analizu (vidi potpoglavlje 2.8.). Za njihovu primjenu preporučuje se kategorizacija podataka. Kategorizacija se provodi na sljedeći način:

- (1) Cjelokupna baza podataka. Sastoji se od 319 zapisa, gdje zapis označava točku na krivulji kumulativnog napretka sa definiranim vremenom i iznosom naplaćenim mjesečnom situacijom u tom trenutku.
- (2) Vrijednost projekta. Podatci se dijele prema vrijednosti projekta, pri čemu je granica kategorizacije postavljena na 10 milijuna eura. Projekti ispod 10 milijuna eura imaju 132 zapisa, dok projekti iznad 10 milijuna eura imaju 187 zapisa. Kategorizacija se temelji na prethodnim istraživanjima iz literature. Santana (1990) klasificira projekte u male (do 1 milijun britanskih funti), srednje (1–10 milijuna britanskih funti) i velike (preko 10 milijuna britanskih funti), dok Safa i dr. (2015) razlikuju normalne projekte (do 10 milijuna američkih dolara), složene projekte (10–100 milijuna američkih dolara), velike projekte (preko 100 milijuna američkih dolara) i megaprojekte (preko 1 milijarde američkih dolara). Prag od 10 milijuna eura odabran je kao odgovarajući za kontekst europskih građevinskih projekata, reflektirajući navedene klasifikacije.
- (3) Tip projekta. Podatci se razvrstavaju prema tipu građevinskih projekata, pri čemu se primijenjuje isti pristup kategorizaciji kao u potpoglavlju 3.2.1. Kategorije uključuju komunalnu infrastrukturu sa 61 zapisom, cestovnu infrastrukturu sa 172 zapisa i visokogradnju sa 86 zapisa.

Nakon što su definirane kategorije u koje se baza podataka može podijeliti, testiraju se različiti matematički modeli za svaku od kategorija. Opći matematički izrazi navedeni su u nastavku:

Polinom 4. stupnja
$$y = ax^4 + bx^3 + cx^2 + dx + e \quad (3)$$

Polinom 3. stupnja
$$y = ax^3 + bx^2 + cx + d \quad (4)$$

Beta distribucija (CDF)
(Kim i Reinschmidt, 2009)
$$y = \int_0^{x_0} \frac{x^{a-1}(1-x)^{b-1}}{B(a,b)} \quad (5)$$

Gompertzova funkcija
(Gompertz, 1825)
$$y = Ae^{-Be^{-kx}} \quad (6)$$

Weibullova distribucija (CDF)
(Nassar i dr., 2005)
$$y = 1 - e^{-\left(\frac{y}{a}\right)^b} \quad (7)$$

Rayleighova distribucija (CDF)
(Wadi, 2023)

$$y = 1 - e^{\frac{-x^2}{2\sigma^2}} \quad (8)$$

Logistička distribucija
(Kucharavy i De Guio, 2012)

$$y = \frac{L}{1 + e^{-k(x-x_0)}} \quad (9)$$

Peer (1982)

$$y = 0,0089 + 0,26981x + 2,36949x^2 - 1,39030x^3 \quad (10)$$

Boussabain i Elhag (1999)

$$y = \frac{9x^2}{4} \text{ za } 0 < x < \frac{1}{3} \quad (11)$$

$$y = \frac{9x}{4} - \frac{1}{4} \text{ za } \frac{1}{3} < x < \frac{2}{3} \quad (12)$$

$$y = \frac{9x}{4} - \frac{9x^2}{4} - \frac{5}{4} \text{ za } \frac{2}{3} < x < 1 \quad (13)$$

Za svaku kategoriju podataka određuje se optimalna struktura polinoma, a parametri specifičnih matematičkih modela se optimiziraju kako bi se osigurala što bolja usklađenost s podacima. Optimizacija modela provodi se pomoću softvera Excel i alata Data Solver s ciljem preciznog prilagođavanja parametara svakog matematičkog modela i minimiziranja MSE između predviđenih i stvarnih podataka iz baze građevinskih projekata. Time se omogućava odabir optimalnog matematičkog modela za svaku kategoriju krivulji kumulativnog napretka.

3.3.2. Proces razvoja modela neuronske mreže

Nakon provedenih koraka pripreme podataka, uključujući njihovo prikupljanje i normalizaciju, u izradi modela neuronske mreže potrebno je dodatno obraditi i kategorijsku značajku (tip projekta). Na značajku se primjenjuje metoda „One-Hot Encoding“ kako bi bila prikladna za korištenje u modelu. Cjelokupni kod korišten za razvoj modela predviđanja krivulje kumulativnog napretka dostupan je u prilogu C, a prikupljeni i obrađeni podatci dostupni su u prilogu D.

Podatci se dijele u omjeru 80:20 za treniranje i testiranje, pri čemu se 20 % skupa za treniranje dodatno izdvaja za validaciju. Time se postiže konačna distribucija od 64 % za treniranje, 16 % za validaciju i 20 % za testiranje. Ovakva podjela omogućuje temeljitu procjenu performansi modela i omogućuje bolju provjeru sposobnosti generalizacije modela.

S ciljem pronalaska najbolje arhitekture i hiperparametara neuronske mreže, sljedeći korak je optimizacija. Testiraju se broj slojeva, broj neurona, ispuštanje neurona i

brzina učenja. Broj skrivenih slojeva varira između jednog i dva, dok broj neurona u svakom sloju varira u rasponu od 8 do 32, s koracima od 8. Ispuštanje neurona se koristi kao tehnika regularizacije i testira u rasponu od 0 % do 20 %, s koracima od 10 %. Mehanizam nasumično deaktivira određeni postotak neurona tijekom svake iteracije treninga kako bi se spriječilo prekomjerno prilagođavanje. Za optimizaciju težina koristi se Adam optimizator, poznat po efikasnosti i stabilnosti. Brzina učenja testira se s vrijednostima 0,001, 0,002 i 0,005. Aktivacijska funkcija za skriveni sloj ispituje se u 3 iteracije, za ReLU, tanh i sigmoid, omogućujući temeljitu procjenu njihove učinkovitosti u različitim arhitekturama. Izlazni sloj koristi linearnu aktivacijsku funkciju. Funkcija gubitka je MSE, s obzirom na prirodu regresijskog problema i interval ciljne varijable 0-1, gdje MSE daje naglasak na veće pogreške. Model se trenira kroz 50 epoha, s veličinom serije od 16 podataka po iteraciji. Optimizacija se provodi metodom pretraživanja mreže, pri čemu se ispituje 216 različitih kombinacija. Postupak omogućuje identifikaciju optimalne arhitekture i hiperparametara mreže, pri čemu se odabir konačne kombinacije temelji na analizi metrika koje su opisane u nastavku (potpoglavlje 3.4.).

Ovim pristupom postavljaju se temelji za naknadnu evaluaciju točnosti modela neuronske mreže u usporedbi s matematičkim modelima, s ciljem ispitivanja njihove primjenjivosti u predviđanju krivulje kumulativnog napretka projekta. Ostvarenje petog pomoćnog cilja analizirano je u poglavlju koje se bavi rezultatima (vidi potpoglavlje 4.5.).

3.4. Evaluacija, vizualizacija i validacija modela

Evaluacija, vizualizacija i validacija modela ključni su koraci u osiguravanju pouzdanosti i primjenjivosti modela na stvarnim projektima. Analiza pogrešaka omogućuje razumijevanje performansi modela na neviđenim podacima te identifikaciju mogućnosti za poboljšanja. Kako bi se osigurala objektivna procjena uspješnosti optimalnih modela i omogućila usporedba različitih pristupa, primijenjuju se sljedeće metrike:

- (1) Srednja kvadratna pogreška kvadrira pojedinačne pogreške, čime se veća težina pridaje ekstremnim odstupanjima između stvarnih i predviđenih vrijednosti i omogućava analiza značajnih pogrešaka. Niže vrijednosti MSE ukazuju na bolju točnost modela (Singh i dr., 2016).

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (14)$$

- (2) Korištenje srednje kvadratne pogreške mjeri prosječno odstupanje između stvarnih i predviđenih vrijednosti. Vrijednosti RMSE kreću se od nule do beskonačnosti, pri čemu niže vrijednosti ukazuju na precizniji model. Za razliku od MSE, RMSE ima istu jedinicu mjere kao izvorni podaci i olakšava interpretaciju (Hodson, 2022).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (15)$$

- (3) Srednja apsolutna pogreška (engl. Mean Absolute Error, MAE) mjeri prosječnu apsolutnu pogrešku između stvarnih i predviđenih vrijednosti. Budući da ne kvadrira pogreške, manje je osjetljiva na ekstremne vrijednosti od MSE i RMSE (Trijeti i dr., 2023; Wonguri i Park, 2023).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (16)$$

- (4) Simetrična srednja apsolutna postotna pogreška (engl. Symmetric Mean Absolute Percentage Error, SMAPE) je mjera pogreške predviđanja koja se koristi kao alternativa MAPE zato što umanjuje pristranost prema velikim vrijednostima. Pruža uravnoteženiju procjenu točnosti modela, posebno kada su stvarne vrijednosti blizu nule.

$$SMAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{\frac{|\hat{y}_i| + |y_i|}{2}} \quad (17)$$

- (5) Koeficijent determinacije (engl. coefficient of determination, R^2) mjeri koliko dobro nezavisne varijable objašnjavaju varijabilnost zavisne varijable. Vrijednosti R^2 se kreću između 0 i 1, gdje veća vrijednost ukazuje na bolju sposobnost predviđanja modela (Gyparakis i dr., 2025; Wongburi i Park, 2023).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \frac{\sum y_i}{n})^2} \quad (18)$$

U izrazima (14-18) n predstavlja broj iteracija, y_i su stvarne vrijednosti i $\hat{y}_i$ su predviđene vrijednosti.

Kako bi se bolje razumjeli rezultati modela i njegove performanse, za optimalne modele izrađuju se različite vizualizacije koje omogućuju sveobuhvatnu analizu predviđanja i pogrešaka:

- (1) Funkcija gubitka tijekom treniranja omogućuje praćenje konvergencije modela i identifikaciju eventualnog prekomjernog prilagođavanja ili nedovoljne optimizacije modela.


- (2) Dijagram raspršenja stvarnih i predviđenih vrijednosti koristi se za procjenu preciznosti predviđanja.
- (3) Dijagram raspršenja reziduala otkriva potencijalne sistematske pogreške modela.
- (4) Histogram reziduala omogućuje analizu distribucije pogrešaka, pri čemu simetrična raspodjela oko nule ukazuje na model bez značajne pristranosti.
- (5) Kutijasti dijagram omogućuje vizualnu usporedbu raspodjele stvarnih i predviđenih vrijednosti, identificiranje potencijalnih odstupanja i prisutnost ekstremnih vrijednosti.

Nakon evaluacije i vizualizacije, provodi se unakrsna validacija kako bi se ocijenila stabilnost modela na različitim podjelama podataka i smanjio rizik od prekomjernog prilagođavanja. Modeli predviđanja prekoračenja ugovorenog trajanja i iznosa validiraju se unakrsnom validacijom s tri skupa. Model predviđanja krivulje kumulativnog napretka validira se unakrsnom validacijom s pet skupova. U procesu validacije podatci su podijeljeni u tri, odnosno pet nepovezanih dijelova. Tijekom svake iteracije, model se trenira na većem broju podskupova, dok se jedan skup koristi za testiranje. Postupak se ponavlja tri, odnosno pet puta, pri čemu svaki segment podataka jednom služi kao validacijski skup. Skupovi nisu identični među modelima. Modeli se vrednuju primjenom istih metrika točnosti kao i u fazi evaluacije optimalnog modela (MSE, RMSE, MAE, SMAPE i R^2). Time se omogućuje objektivna usporedba performansi modela na različitim podjelama podataka i provjerava stabilnost.

Za model predviđanja prekoračenja ugovorenog trajanja i iznosa, vizualizacije se izrađuju tijekom evaluacije optimalnog modela na cjelokupnom skupu podataka, uključujući podatke za treniranje i testiranje. Budući da navedeni prikaz već omogućuje detaljan uvid u performanse modela, ponovna vizualizacija istih rezultata u kontekstu unakrsne validacije je suvišna jer ne bi pružila dodatne spoznaje. Umjesto toga, za validaciju ovog modela koriste se isključivo numeričke metrike kako bi se omogućila objektivna usporedba performansi na različitim podjelama podataka. S druge strane, kod modela predviđanja krivulje kumulativnog napretka, zbog većeg broja podataka u vizualizacijama optimalnog modela, vizualizacije uključuju samo podatke iz skupa za testiranje. Stoga je u procesu unakrsne validacije nužno ponoviti vizualizaciju ključnih pokazatelja kako bi se omogućila detaljna analiza performansi modela. U tu svrhu izrađuju se histogram rezidualnih pogrešaka kako bi se provjerila distribucija preostalih grešaka, dijagram raspršenja stvarnih i predviđenih vrijednosti radi ocjene preciznosti modela, dijagram raspršenja reziduala za otkrivanje eventualnih obrazaca u pogreškama te kutijasti dijagram stvarnih i predviđenih vrijednosti koji omogućuje usporedbu raspodjele predviđanja sa stvarnim podacima. Vizualizacije omogućuju dublju analizu performansi modela te ispituju njegovu sposobnost generalizacije na nove podatke.

3.5. Primjena modela i adaptivni ciklus

Nakon razvoja i validacije modela, istraživanje prelazi u fazu praktične primjene u okviru provođenja što-ako analize, s ciljem testiranja funkcionalnosti modela u stvarnim uvjetima građevinskog projekta. Svrha ove faze istraživanja je utvrditi koji rasponi vrijednosti ulaznih značajki vode do ciljanih performansi i ishoda koji zadovoljavaju sve ključne dionike. Time se model ne koristi samo za pasivno predviđanje, već i kao aktivan alat za podršku odlučivanju. Proces primjene modela i adaptivni ciklus prikazani su na slici 16.



Slika 16. Proces primjene modela i adaptivni ciklus

Primjena modela započinje prikupljanjem podataka o građevinskom projektu koji je u fazi izvođenja. Prikupljaju se podaci o ključnim pokazateljima uspješnosti, odnosno značajkama neuronske mreže, prema strukturi opisanoj u tablicama 13 i 14. Nije potrebno prikupljati sve podatke, već samo one koji se odnose na značajke identificirane kao ključne tijekom razvoja modela. Njihov popis prikazan je zasebno u potpoglavljima 4.2.1. i 4.3.1., a objedinjeni pregled u potpoglavlju 5.1. Struktura tablice u Excel datoteci mora odgovarati strukturi opisanoj u tablici 13, pri čemu svi stupci moraju postojati, ali se vrijednosti unose samo za značajke koje su odabrane kao ključne. Za značajke koje nisu relevantne za predviđanje prekoračenja ugovorenog iznosa ili trajanja stupci ostaju prazni.

Budući da izvođači raspolazu većinom relevantnih informacija, predviđeno je da upravo njihovi predstavnici prikupljaju i popunjavaju podatke temeljem objektivne projektne dokumentacije. Na taj se način osigurava konzistentnost i pouzdanost prikupljenih podataka te se istodobno postiže da rezultati istraživanja imaju neposrednu praktičnu vrijednost za same izvođače, osobito u smislu unaprjeđenja poslovanja i jačanja konkurentnosti. Za značajke koje se ne mogu kvantificirati isključivo na temelju dokumentacije i koje se vrednuju kvalitativnim skalama, predstavnici izvođača dodatno prikupljaju procjene ostalih sudionika kroz intervju i/ili anketne upitnike. Ocjene za svaki projekt daju predstavnici ključnih dionika, bez primjene težinskih koeficijenata po skupinama sudionika. Konačne vrijednosti dobivaju se računanjem aritmetičke sredine odgovora po projektu i fazi, a zatim se zaokružuju na najbliži cijeli broj.

Nakon prikupljanja ulaznih podataka, primjenjuju se modeli za predviđanje prekoračenja ugovorenog trajanja i iznosa. Dobiveni rezultati koriste se kao ulazni podatci u model predviđanja krivulje kumulativnog napretka projekta. Izlazne vrijednosti svih primjenjenih modela predviđanja služe kao temelj za raspravu ključnih dionika i donošenje daljnjih odluka.

Kroz otvorenu komunikaciju ključni dionici razmjenjuju mišljenja, komentiraju mogućnosti daljnjeg napretka projekta i procjenjuju odgovaraju li im predviđena odstupanja u odnosu na njihove prioritete, mogućnosti i razinu prihvatljivog rizika. Usporedba predviđene i trenutačno realizirane krivulje kumulativnog napretka pruža dodatni vizualni uvid u mogući razvoj projekta. Dionici odlučuju žele li intervenirati u predviđeno prekoračenje iznosa, trajanja, oboje ili zadržati postojeće stanje. Ako zaključe da su potrebne mjere prilagodbe, proces prelazi u sljedeću fazu primjene. Ona uključuje generiranje kombinacija u Jupyter Notebooku 7.3.2.

Posebna se pozornost posvećuje mogućnosti promjene značajki. Za značajke koje su po svojoj prirodi nepromjenjive, poput ugovorene vrijednosti projekta, postavljaju se nepromjenjivi ulazni parametri koji su jednaki podacima prikupljenim u prvom koraku ove istraživačke faze. Za značajke koje su podložne promjenama definiraju se rasponi

vrijednosti i koraci između njih. U generiranje kombinacija uključuju se samo vrijednosti koje mogu povoljno utjecati na ishod projekta, čime se smanjuje broj ukupnih kombinacija. Značajke koje se ocjenjuju skalom u simulaciju ulaze samo s povoljnim vrijednostima (npr. višom razinom zadovoljstva), dok se za značajke koje se računaju primjenom izraza generiraju vrijednosti iznad ili ispod referentne točke, ovisno o smjeru koji doprinosi smanjenju rizika prekoračenja. Rasponi se zaokružuju na jednu decimalu.

Izlaz iz Jupyter Notebooka 7.3.2. je Excel datoteka koja služi kao novi skup ulaznih podataka za modele predviđanja prekoračenja ugovorenog trajanja i/ili iznosa. Rezultati predviđanja izvoze se u novu Excel datoteku koja omogućuje jednostavnu analizu, sortiranje i filtriranje kombinacija koje ispunjavaju dogovorene uvjete ključnih dionika. Prag prihvatljivog odstupanja dionici definiraju zasebno za svaki projekt uzimajući u obzir tehničke, financijske i organizacijske specifičnosti. Kombinacije koje ostaju unutar dogovorenih granica dodatno se zajednički analiziraju i raspravljaju kako bi se procijenila njihova provedivost. Prednost se daje rješenjima koja zahtijevaju minimalne prilagodbe i promjene koje je moguće provesti u praksi. Završnu odluku o izboru optimalne kombinacije dionici donose zajednički.

Na temelju zajedničkog znanja i stručne procjene izrađuje se plan prilagodbe za postizanje optimalne kombinacije u što kraćem roku. Za svaku mjeru prilagodbe jasno se definiraju odgovorne osobe, rokovi i načini praćenja provedbe. Paralelno se koristi razvijeni model krivulje kumulativnog napretka za praćenje i evaluaciju učinaka mjera prilagodbe.

Nakon toga, proces primjene prelazi iz analitičke u operativnu fazu te započinje implementacija dogovorenog plana prilagodbe. Preporučuje se redovito praćenje i usporedba realizirane i predviđene krivulje kumulativnog napretka, uz mogućnost adaptivnog ciklusa. Proces je zamišljen kao adaptivan i iterativan, čime se omogućuje višekratna primjena, preporučljivo u ciklusima mjesečnog izvještavanja. To osigurava fleksibilnost za prilagodbu u slučaju promjene okolnosti, dostupnih informacija ili prioriteta dionika. Na taj se način planovi i odluke mogu kontinuirano usklađivati s razvojem situacije na terenu, što dodatno naglašava vrijednost modela kao alata za proaktivno i adaptivno upravljanje građevinskim projektima.

Faza primjene modela i adaptivnog ciklusa ispunjava šesti pomoćni cilj istraživanja i potvrđuje njegovu vrijednost kao praktičnog i operativno primjenjivog sustava za donošenje informiranih odluka.

4. REZULTATI ISTRAŽIVANJA I RASPRAVA

U ovom poglavlju prikazuju se rezultati provedenog istraživanja kojim se validira teorijski i evaluacijski okvir i predstavljaju rezultati kvantitativnih modela za predviđanje performansi i ishoda građevinskih projekata.

U potpoglavlju 4.1. prikazuju se rezultati višestruke studije slučaja provedene radi validacije teorijskog i evaluacijskog okvira. Analizira se svaki pojedinačni slučaj i donose zaključci o percepcijama i prioritetima ključnih dionika.

U nastavku se prikazuju rezultati razvoja i evaluacije kvantitativnih modela za predviđanje prekoračenja ugovorenog trajanja (potpoglavlje 4.2.) i ugovorenog iznosa (potpoglavlje 4.3.), pri čemu se detaljno analiziraju odabrane značajke, arhitektura modela i postignute metrike. Potpoglavlje 4.4. donosi zajedničku interpretaciju i raspravu o rezultatima modela predviđanja prekoračenja ugovorenog trajanja i iznosa, uspoređujući ih s relevantnim istraživanjima iz literature i dosadašnjim modelima.

U potpoglavlju 4.5. predstavljaju se rezultati usporedbe postojećih matematičkih modela i razvijenog modela predviđanja krivulje kumulativnog napretka, s naglaskom na analizu njihove točnosti i praktične primjenjivosti.

Prikazani rezultati omogućuju sveobuhvatno sagledavanje postavljenih istraživačkih ciljeva, provjeru hipoteza i potvrdu vrijednosti evaluacijskog okvira i predloženih modela u kontekstu upravljanja građevinskim projektima.

4.1. Rezultati validacije evaluacijskog okvira za predviđanje performansi i ishoda građevinskih projekata

U ovom potpoglavlju prikazuju se rezultati primjene evaluacijskog okvira za predviđanje performansi i ishoda građevinskih projekata. Cilj je potvrditi funkcionalnost okvira u stvarnom kontekstu građevinskih projekata te ispitati percepcije dionika o važnosti, zastupljenosti i razini primjene pojedinih područja performansi. Rezultati se temelje na višestrukoj studiji slučaja koja omogućuje detaljnu analizu pojedinačnih projekata i donošenje zajedničkih zaključaka. Validacija potvrđuje praktičnu korisnost razvijenog okvira i doprinosi ostvarenju istraživačkih ciljeva.

4.1.1. Slučaj A

Projekt označen kao Slučaj A predstavlja javnu investiciju s ugovorenim iznosom od 15,2 milijuna eura. Izgradnja je započela u kolovozu 2016. godine s ugovorenim trajanjem do studenog 2017. godine. Međutim, projekt je dovršen tek u veljači 2019., što predstavlja prekoračenje ugovorenog trajanja od 94 %, dok je ukupna vrijednost

izvedenih radova bila 88 % viša od ugovorenog iznosa. Jedan od najvećih izazova u fazi izvođenja ovog projekta bio je sastav izvođača, odnosno konzorcij triju tvrtki. Zbog stečaja jedne od tvrtki u prvoj fazi izvedbe, radovi su morali biti preraspodijeljeni između preostale dvije tvrtke. Iako je u početku postignuta određena razina prilagodbe kroz dodatnu radnu snagu i optimizaciju resursa, daljnja koordinacija među izvođačima bila je izuzetno otežana. Dodatne komplikacije proizašle su iz neslaganja među preostalim članovima konzorcija u vezi s raspodjelom radova, narušile odnose unutar konzorcija i dovele do novih kašnjenja. Posljedično, jedna od tvrtki bila je primorana preuzeti sav posao do završetka projekta. Uz organizacijske izazove, projekt se suočio i s financijskim poteškoćama. Problemi u osiguravanju kontinuiteta financiranja doveli su do značajnih izmjena u opsegu projekta kako bi se omogućila realizacija ključnih ciljeva. Nadalje, među većim izazovima bili su nepredviđeni radovi povezani s geološkim uvjetima, koji u fazi projektiranja nisu bili adekvatno istraženi. Navedeni problemi doveli su do dodatnih kašnjenja jer je bilo potrebno revidirati tehnička rješenja i pronaći alternativne metode izvedbe. Osim toga, investitor je morao preusmjeriti dio sredstava kako bi osigurao dovršetak ključnih segmenata projekta. Unatoč svim poteškoćama, projekt je naposljetku završen, a dionici su izrazili zadovoljstvo finalnim ishodom. Međutim, tijekom intervjua su naglasili kako bi bolja koordinacija, preciznije planiranje i jasnija komunikacija između svih dionika mogli značajno smanjiti rizik od kašnjenja i prekoračenja troškova u budućim projektima.

4.1.2. Slučaj B

Slučaj B predstavlja javno ulaganje od 18,7 milijuna eura s ugovorenim trajanjem od studenog 2017. do travnja 2020. godine. Projekt je dovršen tek u ožujku 2021., čime je prekoračeno inicijalno ugovoreno trajanje za 37 %. Iako je u početnim fazama procijenjeno da će troškovi biti niži te je ugovor aneksom smanjen za 30 %, projekt je na kraju premašio inicijalno ugovoreni iznos za 5 %. Jedan od ključnih problema na ovom projektu bio je vezan uz otkriće povijesno značajnih ostataka na gradilištu, što je rezultiralo obustavom radova i provedbom konzervatorskih istraživanja. Proces je izazvao višemjesečna kašnjenja i doveo do potrebe za prilagodbama u izvedbi. Dodatni izazov predstavljala je pandemija COVID-19, koja je utjecala na dostupnost građevinskih materijala i uzrokovala značajne promjene u njihovim cijenama. Svi dionici su izrazili nezadovoljstvo projektnom dokumentacijom, a učestali dodatni i nepredviđeni radovi zahtijevali su stalne izmjene i dorade projektne i ugovorne dokumentacije. Loša komunikacija i loša atmosfera među investitorima, nadzornim inženjerima i izvođačima značajno su utjecali na rješavanje projektnih problema. Dionici su zaključili da je kohezija sudionika projekta mogla biti jača te su neki sudionici bili ocijenjeni kao nedovoljno stručni za pozicije koje obnašaju. Unatoč svim izazovima,

projekt je uspješno završen, a svi dionici bili su zadovoljni konačnim ishodom. Međutim, važno je istaknuti da su jasnija komunikacijska pravila i bolja suradnja među dionicima mogli značajno smanjiti rizik od nastanka problema tijekom izvođenja.

4.1.3. Slučaj C

Projekt označen kao Slučaj C predstavlja javnu investiciju s ugovorenim iznosom od 22,7 milijuna eura. Izgradnja je započela u rujnu 2019. godine s planiranim rokom završetka u prosincu 2021. godine. Projekt je uspješno dovršen unutar ugovorenog trajanja, no niz aneksa tijekom provedbe doveo je do prekoračenja ugovorenog iznosa za 13 %. Jedan od ključnih izazova s kojima se projekt suočio bila je fluktuacija cijena građevinskih materijala i usluga tijekom pandemije COVID-19. Budući da ugovor nije predviđao kliznu ljestvicu za prilagodbu ovim promjenama, izvođač nije imao mogućnost nadoknade povećanih troškova, čime su stvorene financijske poteškoće i otežano planiranje resursa. Tijekom provedbe projekta uočeni su i problemi s projektnom dokumentacijom. Odstupanja između ugovorenih i stvarnih količina radova dovela su do netočnih procjena troškova i pojave nepredviđenih radova. Ispitanici su naveli da su neke ugovorene stavke bile nepotrebne, dok ključne stavke za izvedbu nisu bile dovoljno precizno definirane, što je dovelo do dodatnih radova i povećanja ukupnog troška projekta. Pored financijskih i administrativnih izazova, projekt je obilježila i složenost same lokacije. Gradilište se nalazilo u gusto izgrađenom urbanom području, uz izražena prostorna ograničenja koja su otežavala organizaciju rada, skladištenje materijala i uspostavu gradilišnih komunikacija. Jaki udari vjetra povremeno su onemogućavali izvođenje radova i uzrokovali neplanirane prekide u realizaciji aktivnosti. Osim toga, zbog velikog broja radnika na ograničenom prostoru i primjene različitih tehnologija izvedbe značajno je otežana provedba mjera zaštite na radu, što je bio dodatni izazov za dionike projekta. Unatoč svim poteškoćama, projekt je završen u okviru ugovorenog trajanja, a sudionici su izrazili relativno visok stupanj zadovoljstva konačnim ishodom. Međutim, identificirani problemi upućuju na potrebu za preciznijim planiranjem, jasnijim ugovornim odredbama i većom fleksibilnošću u prilagodbi nepredviđenim okolnostima.

4.1.4. Slučaj D

Slučaj D predstavlja javnu investiciju s ugovorenim iznosom od 19,5 milijuna eura. Početak izvođenja radova bio je u travnju 2019. godine, uz planirano trajanje do ožujka 2021. godine. Projekt je više puta reguliran aneksima i formalno završen unutar ugovorenog roka. Projekt je završen u kolovozu 2021. godine, uz prekoračenje inicijalno ugovorenog trajanja od 22 %. Također, ukupni troškovi projekta premašili su

ugovoreni iznos za 19 %. Investitor je sklopio ugovor s konzorcijem dviju građevinskih tvrtki, no nedostatak koordinacije i loša komunikacija unutar konzorcija predstavljali su jedan od najvećih izazova u provedbi projekta. Ispitanici su istaknuli da jedna od tvrtki nije pratila dinamički plan izvođenja radova, pa je investor bio prisiljen zatražiti preraspodjelu radova kako bi se osigurao kontinuitet izgradnje. Neusklađenost među članovima konzorcija stvorila je dodatni pritisak na drugog izvođača. U kratkom vremenskom roku morao je preuzeti veći dio odgovornosti kako bi se spriječilo daljnje prekoračenje ugovorenog trajanja. Iako su obje tvrtke u konzorciju imale jednake obveze i bile podložne visokim kaznama za nepoštivanje ugovornih rokova, neravnomjerna raspodjela posla dodatno je otežala provedbu projekta. Budući da vremenski okvir nije bio produljen, izvođač se našao u iznimno zahtjevnoj situaciji, prisiljen preuzeti i izvršiti opsežne građevinske radove koji su izvorno bili dodijeljeni njegovom konzorcijskom partneru. Kako bi ispunio ugovorene obveze i izbjegao potencijalni gubitak prihoda, izvođač je morao reorganizirati resurse i ubrzati radove, što je dodatno povećalo operativni rizik. Ispitanici iz skupine izvođača istaknuli su ove izazove i ocijenili da je upravo ugovorni model „ključ u ruke“ bio ključan faktor koji je utjecao na njihovu sposobnost upravljanja nepredviđenim okolnostima. Osim organizacijskih izazova, projekt je karakterizirala visoka razina zahtjeva investitora u pogledu standarda kvalitete izvedbe i sigurnosti na radu. Iako su ti zahtjevi pozitivno utjecali na konačni ishod, dodatno su povećali pritisak na izvođače i komplicirali suradnju između dionika. Sudionici su se složili da bi bolje definirane organizacijske strukture unutar konzorcija, redoviti sastanci svih ključnih dionika i proaktivnije upravljanje građevinskim projektom značajno poboljšali učinkovitost u sličnim projektima u budućnosti.

4.1.5. Slučaj E

Slučaj E odnosi se na javnu investiciju s ugovorenim iznosom od 14,95 milijuna eura, dok je realizirana vrijednost projekta na kraju iznosila 16,6 milijuna eura, čime je inicijalno ugovoreni iznos prekoračen za 11 %. Izgradnja je započela u listopadu 2020. godine, a planirani rok završetka bio je u ožujku 2023. godine. Projekt je konačno dovršen u listopadu 2023. godine, uz više aneksa koji su se potpisali tijekom izvođenja (prekoračenje inicijalno ugovorenog trajanja za 24 %). Na samom početku izvođenja radova na gradilištu su otkriveni povijesno značajni ostaci, s posljedicom značajnog odstupanja od planirane dinamike i kašnjenja od najmanje dva mjeseca. Osim toga, tijekom izvedbe su se pojavili dodatni i nepredviđeni radovi vezani uz geomorfološke karakteristike terena, što je zahtijevalo dodatne izmjene u tehničkoj dokumentaciji i odgodu radova. U više je navrata zabilježeno da su problemi proizlazili su iz neusklađenosti projektne dokumentacije i stvarnog stanja na terenu. Na lokaciji su postojali objekti koji su prema projektu trebali biti uklonjeni prije početka izgradnje, a

njihovo zadržavanje dovelo je do dodatnih radova i produljenja ugovorenog trajanja. Također, problemi s koordinacijom između dionika usporili su donošenje ključnih odluka i dodatno otežali pravovremenu realizaciju projekta. Sudionici istraživanja istaknuli su da je interna komunikacija unutar timova bila zadovoljavajuća, ali su odnosi između predstavnika investitora, izvođača i nadzornih inženjera bili daleko od optimalnih. Sporo rješavanje problema i neefikasna suradnja između dionika dodatno su produljili trajanje projekta. Sudionici su se složili da bi redoviti koordinacijski sastanci i poboljšana timska suradnja mogli značajno smanjiti rizik od budućih kašnjenja i prekoračenja ugovorenog iznosa.

4.1.6. Zaključci višestruke studije slučaja

Planirano je provođenje intervjua sa 65 sudionika, a konačno je sudjelovalo njih 56 (tablica 15), čime je ostvarena stopa odaziva od 86 %. Razgovori su omogućili dubinsku analizu različitih perspektiva o uspješnosti projekata, identificiranje potencijalnih nesuglasica među dionicima te prepoznavanje elemenata koji su najviše utjecali na završne performanse projekata.

Tablica 15. Sudionici uključeni u višestruke studije slučaja

Dionici	Slučaj A	Slučaj B	Slučaj C	Slučaj D	Slučaj E	Ukupno
Investitor	2	2	1	2	1	8
Izvođač	5	6	5	7	5	28
Nadzorni inženjer	3	4	3	4	6	20

Analiza svih slučajeva (tablica 16) pokazuje da su prekoračenja ugovorenog trajanja i iznosa bila česta pojava u svim projektima, pri čemu prosječno prekoračenje ugovorenog trajanja iznosi 35,4 %, dok prosječno prekoračenje ugovorenog iznosa iznosi 27,2 %. Navedena prekoračenja ugovorenog trajanja i iznosa izračunata su prema MacDonalldovoj jednadžbi (2002).

Tablica 16. Pregled slučajeva vezanih uz prekoračenja ugovorenog trajanja i iznosa

Slučaj	Prekoračenje ugovorenog trajanja	Prekoračenje ugovorenog iznosa
Slučaj A	94 %	88 %
Slučaj B	37 %	5 %
Slučaj C	0 %	13 %
Slučaj D	22 %	19 %
Slučaj E	24 %	11 %

Među ključnim uzrocima kašnjenja izdvajaju se problemi u projektiranju i nedostatna projektna dokumentacija koji su doveli do potrebe za učestalim izmjenama ugovora i dodatnim radovima. U gotovo svim analiziranim slučajevima zabilježena su značajna odstupanja između projektiranih i stvarnih količina radova, a posljedica su bili nepredviđeni troškovi i financijske korekcije. Osim tehničkih i administrativnih izazova, komunikacijske barijere među ključnim dionicima pokazale su se kao važan čimbenik koji je utjecao na dinamiku projekta. Projekti u kojima je koordinacija bila slabija imali su veće rizike prekoračenja ugovorenog trajanja i iznosa, dok su projekti s boljom suradnjom među dionicima postizali veću stabilnost u izvedbi.

Na temelju provedenih intervjua, prikupljenih kvantitativnih podataka i analize slučajeva, identificiraju se ključna područja performansi koja su imala najveći utjecaj na uspjeh projekta. Rangiranje područja performansi (tablica 17) ukazuje na razlike u prioritetima različitih dionika. Izvođači i nadzorni inženjeri dijele slične stavove o ključnim područjima performansi koja utječu na uspjeh projekta. Prva četiri područja prepoznaju se kao zajednička. Objašnjenje može biti u njihovim stručnim pozadinama i odgovornostima u okviru provedbe projekta. Investitori najvažnijim smatraju kvalitetu, produktivnost i vrijeme. Iznenadujuće, zadovoljstvo sudionika nije visoko rangirano, unatoč tome što su sudionici u intervjuima isticali njegovu važnost. Razmišljanja sudionika o uspjehu projekta nadilaze tradicionalni model željeznog trokuta. Potrebna je šira definicija ključnih faktora uspjeha koja uključuje i ostala identificirana područja performansi.

Tablica 17. Rangiranje ključnih područja performansi temeljem procjene dionika

Rang	Investitori	Izvođači	Nadzorni inženjeri
1	kvaliteta	profitabilnost	kvaliteta
2	produktivnost	sigurnost	sigurnost
3	vrijeme	kvaliteta	profitabilnost
4	zadovoljstvo sudionika	trošak	trošak
5	trošak	zadovoljstvo investitora	produktivnost
6	sigurnost	produktivnost	vrijeme
7	zadovoljstvo investitora	zadovoljstvo sudionika	zadovoljstvo sudionika
8	profitabilnost	vrijeme	zadovoljstvo investitora

Usporedba rezultata prekoračenja ugovorenog trajanja i iznosa s percepcijama sudionika o važnosti pojedinih područja performansi (tablica 18), upućuje na to da određene dimenzije uspješnosti, poput sigurnosti i zadovoljstva sudionika, mogu imati neposredan utjecaj na izvedbu projekta. Uočena povezanost ukazuje da mjerenje performansi i ishoda projekta nisu odvojeni elementi, već su međusobno uvjetovani.

Tablica 18. Usporedba prekoračenja ugovorenog trajanja i iznosa s percepcijom dionika o ključnim područjima performansi

Dionik / Slučaj	Područja performansi																			
	Profitabilnost					Produktivnost					Kvaliteta					Vrijeme				
	A	B	C	D	E	A	B	C	D	E	A	B	C	D	E	A	B	C	D	E
Investitor																				
Izvođač																				
Nadzorni inženjer																				
Rezultati (prekoračenje)																				
Trajanje																				
Iznos																				

Legenda: zelena – uzeto u obzir, žuta – djelomično uzeto u obzir, crvena – nije uzeto u obzir;
crno – prekoračenje iznosa/trajanja preko 75 %, tamno siva – prekoračenje iznosa/trajanja između 50 – 70 %, siva – prekoračenje iznosa/trajanja između 25 – 50 %, svijetlo siva – prekoračenje iznosa/trajanja između 1 – 25 %, bijela – nema prekoračenja iznosa/trajanja

Na primjer, u Slučaju A, iako su dionici većinom trošak smatrali vitalnim područjem performansi, zajedno s vremenom i kvalitetom (tj. željezni trokut), stvarni rezultati u pogledu prekoračenja trajanja i iznosa nisu bili zadovoljavajući. Zabilježeni nesrazmjer između dioničkih očekivanja i ostvarenih performansi sugerira da uzrok problema leži u drugim područjima performansi i njihovim specifičnim izazovima.

Prekoračenja trajanja i iznosa u Slučaju A prvenstveno se pripisuju području performansi zadovoljstva sudionika, s obzirom da je realizacija planirana unutar konzorcija izvođača. Složenost strukture dionika ukazuje da zanemarivanje zadovoljstva sudionika može značajno negativno utjecati na uspjeh projekta. S druge strane, u Slučaju C, analiza prekoračenja trajanja i iznosa pokazuje relativno zadovoljavajuće rezultate unatoč prekoračenju ugovorenog iznosa od 13 %. U ovom slučaju, sudionici su naglasili važnost područja performansi zadovoljstva sudionika i zadovoljstva investitora, koja su pozitivno doprinijela uspješnom završetku projekta unutar zadanih troškovnih ograničenja i u predviđenom vremenu. Dobiveni uvidi naglašavaju potrebu da se mjerenje performansi ne ograniči isključivo na lako mjerljiva područja, već da se usvoji šira perspektiva upravljanja performansama koja uzima u obzir međusobnu povezanost različitih faktora.

Daljnjom analizom i usporedbom rezultata tablica 17 i 18 postaje jasno da različiti dionici shvaćaju profitabilnost projekta na značajno različite načine, što proizlazi iz njihovih specifičnih uloga i interesa. Budući da se istraživanje odnosi na projekte financirane javnim sredstvima, investitori su profitabilnost rangirali na posljednje mjesto jer njihovi prioriteti uključuju društvene i razvojne ciljeve iznad neposrednog financijskog povrata. Za razliku od njih, izvođači (privatne građevinske tvrtke), rangirali su profitabilnost na prvo mjesto, budući da je ostvarenje dobiti njihov primarni poslovni cilj. Nadzorni inženjeri rangirali su profitabilnost na treće mjesto, odmah iza kvalitete i sigurnosti, pri čemu su u svojim procjenama bliži izvođačima nego investitorima. Ovakav rezultat dijelom proizlazi iz činjenice da i nadzorne službe posluju kao privatne tvrtke, za koje profitabilnost projekta istodobno znači profitabilnost njihova rada, odnosno točnost procjene vremena i resursa potrebnih za izvršenje ugovora te mogućnost njihova uklapanja u ugovoreni iznos.

Takvi stavovi potvrđeni su i kroz rezultate studija slučaja (tablica 18). Investitori su u tri slučaja naveli da profitabilnost nije bila uzeta u obzir, dok su izvođači u svim slučajevima istaknuli da je ona važna i uvijek uzimana u obzir. Nadzorni inženjeri su u četiri slučaja naveli da je bila uzeta u obzir, a u jednom su naveli da nije.

Iako se očekuje da izvođači i nadzorni inženjeri djeluju s moralnom odgovornošću, štite interese investitora te koriste svoje stručno znanje i iskustvo u svrhu optimizacije troškova za investitora bez ugrožavanja kvalitete izvedbe, njihova je sposobnost utjecaja na ukupnu profitabilnost projekta ograničena. To je posebno izraženo u

usporedbi s projektantima, čije odluke u fazi projektiranja u većoj mjeri određuju financijske ishode.

Budući da ovo istraživanje stavlja naglasak na fazu izvođenja radova i aktivno sudjelovanje svih ključnih dionika, profitabilnost se isključuje iz daljnje analize kao metodološka odluka. Njezino različito tumačenje među dionicima onemogućava dosljednu usporedbu i zajedničku evaluaciju uspješnosti, dok se u okviru iterativne analize i podešavanja evaluacijskog okvira osigurava praćenje samo onih područja performansi koja su jasno i jednako definirana svim dionicima. Time se naglasak usmjerava na preostala područja performansi (kvaliteta, vrijeme, trošak, sigurnost, produktivnost, zadovoljstvo sudionika i zadovoljstvo investitora) koja su prepoznata kao zajednički razumljiva i usporediva. Njihova interakcija i međusobna povezanost pružaju temelje za cjelovitiju evaluaciju uspješnosti građevinskih projekata.

Usporedba rezultata višestruke studije slučaja s nalazima iz tablice 4 pokazuje da su najčešće analizirana područja performansi u literaturi (kvaliteta, vrijeme, trošak i sigurnost) doista i prepoznata kao prioritetna od strane dionika. Međutim, ovim istraživanjem potvrđuje se da dodatna područja, poput produktivnosti, zadovoljstva sudionika i zadovoljstva investitora, također imaju mjerljiv utjecaj na uspješnost projekta, iako su u dosadašnjim istraživanjima bila znatno rjeđe obuhvaćena. Stoga je ključno osigurati strukturiran pristup koji omogućuje sustavno prepoznavanje i praćenje performansi. Evaluacijski okvir, validiran kroz višestruku studiju slučaja, pruža takav pristup te omogućava njegovu praktičnu primjenu u predviđanju performansi i ishoda građevinskih projekata.

4.1.7. Povezivanje evaluacijskog okvira s predviđanjem performansi i ishoda građevinskih projekata

Validacija evaluacijskog okvira kroz višestruku studiju slučaja potvrđuje da se analizom ključnih područja performansi može unaprijed identificirati rizik prekoračenja ugovorenog trajanja i iznosa. Time se potvrđuje da evaluacijski okvir nije koristan isključivo kao alat za retrospektivnu procjenu performansi, već i kao osnova za predviđanje izvedbe građevinskih projekata. Na temelju ovih rezultata formuliran je pristup koji povezuje mjerenje performansi s predviđanjem ishoda projekta. Analiza pokazuje da je za učinkovito mjerenje performansi nužno kombinirati objektivne kvantitativne i kvalitativne pokazatelje. Rezultati višestruke studije slučaja potvrđuju hipotezu H1 prema kojoj se primjenom teorije upravljanja dionicima i kvalitativne metode višestruke studije slučaja mogu identificirati ključna područja performansi koja čine temelj za razvoj evaluacijskog okvira za predviđanje ishoda projekata. Potvrda proizlazi iz empirijskih nalaza dobivenih analizom podataka i percepcija dionika.

Prvi važan nalaz odnosi se na razlike u percepcijama uspješnosti među dionicima. Analiza rangiranja ključnih područja performansi pokazuje da investitori, izvođači i nadzorni inženjeri imaju različite prioritete prilikom definiranja uspješnosti projekta. Dok su investitori kao najvažnije istaknuli kvalitetu, produktivnost i vrijeme, izvođači su naglasili sigurnost i troškove, a nadzorni inženjeri dali su prednost kvaliteti i sigurnosti. Evidentirane razlike ukazuju na činjenicu da različite skupine dionika promatraju uspješnost projekta iz vlastite perspektive, što može utjecati na donošenje odluka i međusobnu koordinaciju tijekom provedbe projekta.

Drugi značajan nalaz odnosi se na identificiranje nesklada u percepcijama među dionicima. Polustrukturirani intervjui i analiza Likertovih ljestvica omogućili su prepoznavanje područja u kojima postoji izražena razlika u percepcijama između različitih skupina dionika. Posebno su istaknuti slučajevi u kojima investitori i izvođači nisu dijelili isto mišljenje o važnosti određenih područja performansi, što je ukazalo na potencijalne izvore nesuglasica koje mogu negativno utjecati na dinamiku projekta. Uočena neusklađenost u percepciji važnosti područja performansi dodatno naglašava potrebu za usklađivanjem očekivanja među dionicima te jačanjem komunikacije i suradnje kako bi se smanjili rizici prekoračenja ugovorenog trajanja i iznosa.

Treći ključni nalaz potvrđuje utjecaj komunikacije i suradnje na performanse projekta. Empirijsko testiranje evaluacijskog okvira pokazalo je da projekti s boljom komunikacijom i suradnjom među dionicima ostvaruju bolje rezultate u pogledu prekoračenja ugovorenog trajanja i iznosa. Nalaz o značajnom utjecaju komunikacije i suradnje potvrđuje da uspješnost projekta nije isključivo vezana uz tehničke i financijske čimbenike, već i uz organizacijske i upravljačke. Loša koordinacija među dionicima, nejasno definirane odgovornosti i sporo donošenje odluka pokazali su se kao ključni izazovi koji su doveli do prekoračenja u analiziranim slučajevima.

Na temelju ovih spoznaja razvija se kvantitativni model predviđanja prekoračenja ugovorenog trajanja i iznosa primjenom metoda strojnog učenja. Razvijeni modeli i njihovi rezultati opisuju se u sljedećem potpoglavlju s ciljem povećanja točnosti predviđanja prekoračenja ugovorenog trajanja i iznosa, kao i povećanja pouzdanosti upravljanja rizicima i donošenja odluka tijekom provedbe građevinskog projekta.

4.2. Model predviđanja prekoračenja ugovorenog trajanja

Rezultati višestruke studije slučaja pokazuju da su prekoračenja ugovorenog trajanja česta u analiziranim projektima te potvrđuju važnost pravovremenog predviđanja rizika za sve ključne dionike. Pravodobno i pouzdano predviđanje mogućeg kašnjenja ključno je kako bi dionici mogli na vrijeme poduzeti korektivne mjere, prilagoditi planove i umanjiti neželjene posljedice. S ciljem boljeg razumijevanja čimbenika koji

utječu na nastanak prekoračenja i osiguravanja alata za njegovo predviđanje, u nastavku se prikazuju rezultati razvijenog modela neuronske mreže za predviđanje ugovorenog trajanja. Model se razvija primjenom metoda strojnog učenja. Identificiraju se značajke koje najviše doprinose točnosti predviđanja, model se kroz više faza optimizira i evaluira, a ključni nalazi prikazuju se u nastavku.

4.2.1. Odabir značajki i inicijalna optimizacija modela predviđanja prekoračenja ugovorenog trajanja

Razvoj modela temelji se na paralelnom odabiru značajki koje najviše doprinose točnosti predviđanja i na optimizaciji arhitekture neuronske mreže, uz prilagodbu ključnih hiperparametara. Takav iterativni pristup omogućuje postizanje ravnoteže između preciznosti i sposobnosti generalizacije modela, uz to smanjuje broj potrebnih ulaznih podataka i olakšava praktičnu primjenu i skraćuje vrijeme prikupljanja podataka u stvarnim projektima. Kao što je opisano u potpoglavlju 3.2.2., značajke se rangiraju primjenom algoritma slučajne šume, a modeli se treniraju s postupnim uključivanjem dodatnih značajki prema redoslijedu važnosti. U isto vrijeme testiraju se različite arhitekture mreže i kombinacije hiperparametara, čime se dodatno provjerava utjecaj broja značajki na performanse modela. U nastavku se stoga najprije prikazuju objedinjeni rezultati testiranja kombinacija značajki i arhitektura, zatim se objašnjava odabir optimalne arhitekture, dok su značajke koje se identificiraju ključnima detaljno obrazložene na kraju potpoglavlja.

Tablica 19 prikazuje rezultate modela predviđanja za svaku kombinaciju broja značajki i pripadajuće arhitekture mreže. Za svaki broj značajki odabrana je ona arhitektura koja postiže najbolje evaluacijske metrike, a rangiranje je provedeno prema najmanjoj vrijednosti MSE. Testirane su različite arhitekture mreže i rasponi vrijednosti ključnih hiperparametara. Analiza rezultata pokazuje da modeli s manjim brojem značajki (6 do 10 značajki) generalno postižu niže vrijednosti MSE, RMSE i MAE, što sugerira da selektivno uključivanje značajki poboljšava performanse modela. Dodavanje značajki ne utječe nužno na poboljšanje performansi. U prilog tome, analiza modela s većim brojem značajki (13 i više) pokazuje porast vrijednosti metrika, pad u performansama te sugerira potencijalni problem prekomjernog prilagođavanja ili potencijalni šum u podacima.


Analizirajući utjecaj arhitekture mreže, vidljivo je da modeli s jednim skrivenim slojem često postižu bolje rezultate od modela s dva sloja. Dodavanje drugog skrivenog sloja u većini slučajeva ne doprinosi značajnom poboljšanju, osim u nekoliko specifičnih kombinacija.

Tablica 19. Pregled optimalnih kombinacija broja značajki i arhitekture mreže s pripadajućim performansama (model predviđanja prekoračenja ugovorenog trajanja)


Broj značajki	Broj skrivenih slojeva	Broj neurona (1.sloj)	Broj neurona (2.sloj)	Ispuštanje neurona (1.sloj)	Ispuštanje neurona (2.sloj)	Stopa učenja	Aktivacijska funkcija	MSE	RMSE	MAE	SMAPE	R ²
9	2	32	8	0	0	0,010	tanh	0,0222	0,1474	0,1200	50,39	0,6485
10	1	40		0		0,005	tanh	0,0255	0,1529	0,1165	42,26	0,6811
11	2	16	8	0	0	0,010	tanh	0,0258	0,1571	0,1184	50,09	0,6359
12	1	40		0,1		0,005	tanh	0,0260	0,1586	0,1200	43,77	0,6093
8	1	16		0		0,010	relu	0,0289	0,1680	0,1276	47,52	0,5556
7	2	32	32	0	0	0,010	relu	0,0291	0,1681	0,1277	46,18	0,6038
16	2	40	32	0	0	0,005	tanh	0,0310	0,1706	0,1300	49,30	0,5956
14	2	40	8	0	0	0,010	tanh	0,0315	0,1727	0,1337	46,83	0,5817
13	1	32		0		0,010	tanh	0,0327	0,1673	0,1385	56,83	0,6315
15	2	32	32	0,2	0,2	0,010	tanh	0,0330	0,1807	0,1415	47,52	0,5317
20	1	32		0		0,010	relu	0,0336	0,1758	0,1396	50,54	0,6226
18	1	32		0		0,010	tanh	0,0346	0,1806	0,1436	49,95	0,4709
6	1	40		0,3		0,005	relu	0,0357	0,1879	0,1484	48,50	0,5144
19	2	32	32	0,2	0,3	0,010	tanh	0,0358	0,1836	0,1473	52,78	0,4939
22	2	32	32	0,1	0,1	0,005	tanh	0,0359	0,1878	0,1453	47,79	0,4153
17	2	32	32	0	0	0,010	tanh	0,0387	0,1886	0,1559	56,23	0,5036
21	2	40	32	0	0,1	0,005	tanh	0,0404	0,1945	0,1595	58,08	0,4170
4	1	8		0,1		0,010	relu	0,0468	0,2148	0,1778	54,94	0,3713
5	2	8	8	0	0,2	0,010	relu	0,0535	0,2296	0,1896	58,71	0,2814
3	2	8	8	0	0	0,005	relu	0,0608	0,2451	0,2117	65,25	0,1258

Primjerice, model s 9 značajki i arhitekturom s 32 neurona u prvom skrivenom sloju i 8 u drugom skrivenom sloju ostvaruje najnižu vrijednost MSE i RMSE, ali je prema ostalim metrikama bio nešto slabiji. Što se tiče aktivacijske funkcije, tanh se ističe kao najčešće prisutna aktivacijska funkcija u najbolje rangiranim modelima, dok ReLU bilježi niže performanse. Uspješnija primjena funkcije tanh ukazuje na njezinu veću sposobnost modeliranja odnosa među značajkama u ovom kontekstu. Najbolje rezultate ostvarili su modeli sa stopom učenja od 0,010 ili 0,005, uz stabilnu konvergenciju tijekom procesa treniranja. Stopa učenja od 0,001 nije dovela do poboljšanja, uzrokovala je više vrijednosti MSE i nije se pojavila ni u jednoj optimalnoj kombinaciji značajki.

Iako model s 9 značajki ostvaruje najniže vrijednosti MSE i RMSE, model s 10 značajki pokazuje se boljim prema metrikama MAE, SMAPE i R^2 . Usporedbom krivulja gubitka za model s 9 značajki (slika 17) i 10 značajki (slika 18) uočava se opadajući trend i ukazuje da model uspješno uči iz podataka.



Slika 17. Gubitak kroz epohe za neuronsku mrežu s 9 značajki (model predviđanja prekoračenja ugovorenog trajanja)



Slika 18. Gubitak kroz epohe za neuronsku mrežu s 10 značajki (model predviđanja prekoračenja ugovorenog trajanja)

Međutim, razlika između dva modela očituje se u stabilnosti konvergencije. Model s 9 značajki pokazuje oscilacije kroz epohe, što može upućivati na veću osjetljivost na varijacije u podacima. S druge strane, model s 10 značajki ima glađu krivulju gubitka, što sugerira njegovu veću stabilnost i manju osjetljivost na varijacije podataka. Iako razlike nisu drastične, veća stabilnost i bolja konvergencija su ključni razlozi za odabir ovog modela kao optimalnog.


Dodatna potvrda odluke proizlazi iz analize evaluacijskih metrika razvijenih modela na skupu podataka podijeljenom u omjeru 80:20 na skup za treniranje i testiranje (tablica 20). Model s 10 značajki ostvaruje bolje rezultate u svim metrikama u usporedbi s modelom s 9 značajki. Rezultati potvrđuju njegovu veću sposobnost generalizacije i preciznije predviđanje odstupanja od ugovorenog trajanja, zbog čega se odabire kao optimalan model inicijalne optimizacije.

Tablica 20. Usporedba performansi modela neuronske mreže s 9 i 10 značajki (model predviđanja prekoračenja trajanja)


Metrika	Model s 9 značajki	Model s 10 značajki
MSE	0,0086	0,0086
RMSE	0,0930	0,0928
MAE	0,0801	0,0784
SMAPE	20,92 %	19,05 %
R ²	0,8486	0,8490

Nakon odabira optimalnog modela, analiziraju se predviđanja na testnom skupu podataka. Usporedbom stvarnih i predviđenih vrijednosti (slika 19) vidljivo je da model relativno dobro prati trend stvarnih vrijednosti, ali se uočavaju određena odstupanja. Model pokazuje zadovoljavajuću preciznost u predviđanju prosječnih vrijednosti, no dolazi do odstupanja kod ekstremnih vrijednosti. Najveća odstupanja uočena su u primjerima 4, 5 i 7. Razlog može biti ograničenje skupa podataka ili nedovoljna sposobnost modela da primjereno prilagodi težine u ekstremnim slučajevima, što ukazuje na potrebu za daljnjom optimizacijom modela.

Tablica 22, koja je smještena u kasnijem potpoglavlju radi povezanosti s naknadnim analizama, prikazuje usporedbu numeričkih vrijednosti stvarnih i predviđenih rezultata. Kako bi se bolje razumjeli ključni pokazatelji uspješnosti koji utječu na predviđanje prekoračenja ugovorenog trajanja, provodi se analiza relativne važnosti značajki. Slika 20 prikazuje vizualizaciju relativne važnosti pojedinih značajki u modelu s 10 značajki. Rezultati analize identificiranih značajki potvrđuju da prekoračenje ugovorenog trajanja ne ovisi isključivo o tehničkim čimbenicima, već i o komunikaciji i prilagodljivosti tijekom projekta.



Slika 19. Usporedba stvarnih i predviđenih vrijednosti nakon optimizacije (model predviđanja prekoračenja ugovorenog trajanja)



Slika 20. Relativna važnost pojedinih značajki u modelu predviđanja prekoračenja ugovorenog trajanja

Analiza značajki modela ukazuje da je najvažnija značajka analiza dinamičkog plana, s udjelom od 32,63 % ukupne važnosti. Analiza dinamičkog plana najviše doprinosi predviđanju i dodatno potvrđuje ključnu ulogu planiranja i dinamike u sprječavanju kašnjenja. Upravljanje sukobima (10,90 %) također se izdvaja kao snažan utjecajni faktor jer nedostatak komunikacije i koordinacije može znatno otežati pravovremeno dovršenje projekta. Ugovorena vrijednost radova (8,74 %) naglašava važnost financijskih aspekata u uspješnosti provedbe. Kao sljedeća značajka po važnosti je tip projekta, pri čemu cestovni infrastrukturni projekti (7,52 %) imaju veći značaj u odnosu

na ostale tipove. Trend promjena i dodatnih radova (5,44 %) upućuje na učestalost izmjena koje mogu imati izravan učinak na rokove i budžet. Među ključnim značajkama ističu se i subjektivni čimbenici, poput zadovoljstva investitora stručnošću izvođača (5,32 %) te zadovoljstva sudionika (3,69 %), što dodatno naglašava važnost odnosa među dionicima tijekom izvedbe projekta. Pridržavanje rokova aktivnosti (4,39 %) očekivano je važan faktor, budući da pravovremena realizacija zadataka utječe na tijek radova. Upravljanje promjenama (3,78 %) potvrđuje da prilagodljivost i sposobnost upravljanja nepredviđenim situacijama igra značajnu ulogu u uspjehu projekta. Kvaliteta projektne dokumentacije (3,61 %) također je prepoznata kao važan element jer neprecizne ili nepotpune informacije mogu dovesti do kašnjenja i dodatnih problema.


Rezultati inicijalne optimizacije pokazuju da se uravnoteženim odabirom značajki i optimalnim podešavanjem arhitekture modela mogu postići pouzdani rezultati u predviđanju prekoračenja ugovorenog trajanja građevinskih projekata. Model s 10 značajki izdvojio se kao optimalan jer u kombinaciji s odabranom arhitekturom postiže stabilnu konvergenciju, uravnotežene evaluacijske metrike i veću sposobnost generalizacije u odnosu na ostale testirane kombinacije. Analiza važnosti značajki potvrđuje da uklanjanje manje relevantnih značajki smanjuje rizik od prekomjernog prilagođavanja. Sljedeći koraci uključuju dodatnu optimizaciju hiperparametara s ciljem povećanja točnosti predviđanja.

4.2.2. Dodatna optimizacija hiperparametara i analiza performansi modela predviđanja prekoračenja ugovorenog trajanja

Kako bi se dodatno poboljšala stabilnost modela i povećala njegova sposobnost generalizacije, provodi se dodatna optimizacija ključnih hiperparametara neuronske mreže. Dodatna optimizacija temelji se na sustavnom testiranju različitih kombinacija hiperparametara, s naglaskom na poboljšanje evaluacijskih metrika na testnom skupu, u skladu s metodološkim pristupom opisanom u potpoglavlju 3.2.4. Cilj je odabrati kombinaciju koja smanjuje pogreške modela i povećava njegovu sposobnost generalizacije na nepoznatim podacima.

Prije same optimizacije hiperparametara, ključno je razumjeti distribuciju ciljne varijable kako bi se identificirali potencijalni izvori pogrešaka i utvrdila potreba za primjenom metoda balansiranja podataka. Histogram prikazan na slici 21 pokazuje da je većina vrijednosti u skupu za treniranje koncentrirana u rasponu od 0,2 do 0,6, s najviše pojavljivanja oko 0,4. Distribucija skupa za testiranje je slična, ali s manjim brojem uzoraka zbog čega skup nije ravnomjerno podijeljen po cijelom rasponu vrijednosti. U oba skupa se primjećuje manji broj uzoraka na krajevima distribucije (blizu 0,0 i 1,0), što može objasniti povećanu pogrešku modela za slučajeve predviđanja


ekstremnih vrijednosti. Na temelju rezultata analize distribucije, zaključuje se da podatci nemaju značajnu neuravnoteženost te nema potrebe za primjenom SMOGN.



Slika 21. Distribucija ciljne varijable (model predviđanja prekoračenja ugovorenog trajanja)

Konačni rezultati optimizacije pokazuju da optimalan model koristi stopu učenja od 0,001, ispuštanje neurona od 15 %, veličinu serije podataka 16 i SGD optimizator bez momenta. Niža vrijednost stope učenja omogućuje stabilnije prilagođavanje težina modela, čime je postignuta bolja stabilnost modela i smanjena varijabilnost u rezultatima. Istovremeno, uključivanje ispuštanja neurona od 15 % doprinosi sprječavanju prekomjernog prilagođavanja, dok SGD optimizator ostvaruje bolje rezultate u odnosu na Adam i RMSprop.

Kombinacija hiperparametara omogućuje stabilniji proces treniranja, što se potvrđuje analizom funkcije gubitka kroz epohe (slika 22).



Slika 22. Gubitak modela predviđanja prekoračenja ugovorenog trajanja kroz epohe (nakon dodatne optimizacije)


Vidljivo je da model postupno smanjuje vrijednost gubitka, bez prisutnosti značajnih oscilacija. Krivulja ukazuje na stabilnu konvergenciju uz postupno smanjenje vrijednosti MSE. Model dosljedno uči iz podataka i ne pokazuje znakove prekomjernog prilagođavanja.

Rezultati analize performansi dodatno optimiziranog modela prikazani su u tablici 21. Pokazuju da model postiže niže vrijednosti MSE, RMSE, MAE i SMAPE na skupu za testiranje u odnosu na skup za treniranje, što ukazuje na dobru sposobnost generalizacije i odsutnost prekomjernog prilagođavanja. Visoka vrijednost R^2 potvrđuje da model objašnjava većinu varijacija u podacima. Usporedba metrika u tablicama 20 i 21 pokazuje poboljšanje performansi modela kroz smanjenje MSE, RMSE i MAE na testnom skupu, dok viša vrijednost R potvrđuje veću sposobnost objašnjavanja varijabilnosti ciljne varijable.

Tablica 21. Usporedba performansi na skupu za treniranje i testiranje (model predviđanja prekoračenja ugovorenog trajanja)

Metrika	Skup za treniranje	Skup za testiranje
MSE	0,0128	0,0029
RMSE	0,1130	0,0536
MAE	0,0871	0,0435
SMAPE	39,49 %	32,32 %
R^2	0,8693	0,9497

Pored numeričke analize, vizualizacija na slici 23 prikazuje usporedbu stvarnih i predviđenih vrijednosti nakon dodatne optimizacije. Model sada preciznije prati stvarne vrijednosti, uključujući i ekstremne slučajeve, gdje su prethodne verzije modela pokazivale veća odstupanja.




Slika 23. Usporedba stvarnih i predviđenih vrijednosti nakon dodatne optimizacije (model predviđanja prekoračenja ugovorenog trajanja)

Usporedba numeričkih vrijednosti nakon inicijalne i dodatne optimizacije (tablica 22) dodatno potvrđuje da je model postao precizniji. Inicijalna verzija modela pokazivala je tendenciju precjenjivanja nižih vrijednosti i podcjenjivanja viših, a dodatno optimizirani model pokazuje bolju ravnotežu u predviđanjima. Smanjena odstupanja posebno su vidljiva kod predviđanja nižih vrijednosti, što ukazuje da je optimizacija poboljšala prilagodljivost modela u slučajevima gdje su ranije postojale veće greške (primjeri 4, 5 i 7). Time je povećana ukupna pouzdanost modela i njegova sposobnost preciznijeg predviđanja prekoračenja ugovorenog trajanja u građevinskim projektima.

Tablica 22. Usporedba stvarnih vrijednosti i predviđenih vrijednosti (model predviđanja prekoračenja ugovorenog trajanja)


Primjer	Stvarna vrijednost	Predviđena vrijednost nakon inicijalne optimizacije	Predviđena vrijednost nakon dodatne optimizacije
1	0,8172	0,8045	0,7838
2	0,3201	0,2785	0,3276
3	0,4783	0,3915	0,3843
4	0,5663	0,7342	0,6351
5	0,0000	0,1066	0,0533
6	0,5663	0,5765	0,4945
7	0,6973	0,8128	0,7020
8	0,3201	0,4465	0,3058

Slika 24 prikazuje odnos između stvarnih i predviđenih vrijednosti modela, pri čemu crvena isprekidana linija predstavlja idealna predviđanja. Analiza raspodjele točaka pokazuje da većina predviđanja dobro prati ovu liniju, što sugerira da model generalno dobro predviđa vrijednosti. Skup za testiranje pokazuje sličan obrazac kao i skup za treniranje, čime se potvrđuje sposobnost generalizacije i izostanak prekomjernog prilagođavanja. Najveća usklađenost između stvarnih i predviđenih vrijednosti vidljiva je u srednjem rasponu, između 0,3 i 0,8, gdje su odstupanja najmanja. Na krajevima distribucije bilježe se veće pogreške, osobito pri predviđanju ekstremnih vrijednosti. Uočeni obrazac podudara se sa zaključcima analize distribucije ciljne varijable, koja pokazuje smanjenu zastupljenost uzoraka u tim intervalima i time otežava precizno učenje modela.




Slika 24. Dijagram raspršenja stvarnih i predviđenih vrijednosti (model predviđanja prekoračenja ugovorenog trajanja)

Slika 25 prikazuje rezidualne vrijednosti modela, odnosno razlike između stvarnih i predviđenih vrijednosti te omogućava uvid u preciznost predviđanja i potencijalne obrasce grešaka. Reziduali su približno ravnomjerno raspoređeni oko nule, što ukazuje da model nema izraženu pristranost prema previsokim ili preniskim predviđanjima. Raspon reziduala kreće se između -0,3 i 0,2, bez izrazitih ekstremnih odstupanja. Opći uzorak grešaka ukazuje da model nije sklon sustavnom precjenjivanju ili podcjenjivanju predviđanja, što je ključan aspekt njegove pouzdanosti.



Slika 25. Rezidualne vrijednosti modela predviđanja prekoračenja ugovorenog trajanja

Kutijasti dijagram (slika 26) i pripadajuća analiza statističkih pokazatelja distribucije (tablica 23) prikazuju raspon pogrešaka u skupu za treniranje i testiranje.



Slika 26. Kutijasti dijagram grešaka predviđanja (model predviđanja prekoračenja ugovorenog trajanja)

Interkvartilni raspon je nešto širi u skupu za treniranje nego u skupu za testiranje, što znači da su greške na trening podacima nešto varijabilnije. U skupu za treniranje postoji jedno izraženo odstupanje blizu -0,3, dok takvih ekstremnih vrijednosti nema u skupu za testiranje. Razlika ukazuje da se u pojedinim slučajevima model suočava s izazovima u preciznom predviđanju specifičnih primjera, ali bez značajnih utjecaja na ukupne performanse. Srednja vrijednost pogreške blizu nule za oba skupa potvrđuje da model nema izraženu pristranost u jednom smjeru. Blago negativan medijan u skupu za treniranje (-0,0206) ukazuje na učestalije podcjenjivanje. U testnom skupu, viši medijan (0,0048) odražava blagu tendenciju precjenjivanja.

Tablica 23. Statistički pokazatelji distribucije (model predviđanja prekoračenja ugovorenog trajanja)

Statistički pokazatelj	Skup za treniranje	Skup za testiranje
Srednja vrijednost greške	-0,0206	0,0099
Medijan greške	-0,0220	0,0048
Standardna devijacija	0,1131	0,0563
Asimetrija distribucije	-0,3734	0,0854
Spljoštenost distribucije	-0,0886	-1,0577
Interkvartilni raspon	0,1286	0,0620

Standardna devijacija je također veća u skupu za treniranje i sugerira veću varijabilnost pogrešaka u skupu za treniranje, dok su predviđanja na skupu za testiranje konzistentnija. Blaga asimetrija distribucije grešaka dodatno potvrđuje ovu tendenciju. Negativna spljoštenost distribucije u oba skupa znači da distribucija grešaka nema izražene ekstreme i dobar je pokazatelj stabilnosti modela.

Na temelju provedenih analiza, model pokazuje stabilnost i sposobnost uspješne generalizacije. Dodatna optimizacija hiperparametara značajno je poboljšala performanse modela. Na testnom skupu zabilježene su niže vrijednosti MSE, RMSE, MAE i SMAPE i povećana vrijednost R^2 u odnosu na skup za treniranje. Također, usporedba stvarnih i predviđenih vrijednosti prije i nakon dodatne optimizacije jasno pokazuje napredak modela u točnosti predviđanja.

4.2.3. Unakrsna validacija modela predviđanja prekoračenja ugovorenog trajanja

Validacija modela provodi se unakrsnom validacijom s tri skupa, čime se osigurala pouzdana procjena njegove stabilnosti i sposobnosti generalizacije na različite podjele podataka. Primjena validacije omogućuje testiranje modela na različitim segmentima skupa podataka, smanjujući utjecaj slučajnosti pri odabiru skupa za treniranje i testiranje. Rezultati unakrsne validacije prikazani su u tablici 24 te su pokazali stabilnost i dobru sposobnost modela predviđanja.

Tablica 24. Rezultati metrika unakrsne validacije (3 skupa modela predviđanja prekoračenja ugovorenog trajanja)

Skup	MSE	RMSE	MAE	SMAPE	R^2
Skup 1	0,0059	0,0768	0,0574	43,16 %	0,9122
Skup 2	0,0104	0,1019	0,0744	35,43 %	0,9316
Skup 3	0,0183	0,1353	0,1054	31,55 %	0,5633
Prosjek	0,0115	0,1047	0,0791	36,71 %	0,8025

Analiza prosječnih vrijednosti metrika potvrđuje da model ima niske pogreške i stabilno predviđanje. MSE se kreće u rasponu od 0,0059 do 0,0183, s prosječnom vrijednošću od 0,0115. Navedene vrijednosti sugeriraju nisku razinu pogreške modela, pri čemu se najmanje odstupanje bilježi u prvom skupu. Prosječan RMSE iznosi 0,1047, s predviđanjima koja su u prosjeku vrlo blizu stvarnim vrijednostima. MAE iznosi u prosjeku 0,0791, pri čemu najmanju vrijednost bilježi prvi skup (0,0578). Unatoč razlikama među skupovima, MAE ostaje na razini koja ukazuje na relativno mala odstupanja predviđanja u odnosu na stvarne vrijednosti. SMAPE iznosi u prosjeku

36,71 %. U pojedinim skupovima SMAPE bilježi nešto više vrijednosti, no ostaje u prihvatljivim okvirima. Viša odstupanja povezana su s prisutnošću podataka blizu nule, koji negativno utječu na točnost ove metrike. Koeficijent determinacije pokazuje visoku sposobnost modela da objasni varijabilnost podataka, s prosječnom vrijednošću od 0,8025. Skupovi 1 i 2 postižu vrlo visoke vrijednosti R^2 (0,9122 i 0,9316), dok je u trećem skupu značajno niži (0,5633), što ukazuje da model na određenim podjelama podataka može imati ograničenja u obuhvaćanju svih obrazaca. Razlika može biti posljedica različite distribucije podataka u trećem skupu, no i dalje pokazuje da model može prepoznati obrasce u podacima s visokom točnošću.

Unakrsna validacija potvrđuje da model dosljedno održava dobre performanse kroz različite podjele podataka, uz minimalne oscilacije u preciznosti predviđanja. Iako postoje razlike među pojedinim skupovima, model pokazuje sposobnost prepoznavanja obrazaca i ostvaruje nisku razinu greške. Rezultati potvrđuju njegovu stabilnost i primjenjivost u realnim uvjetima predviđanja prekoračenja ugovorenog trajanja građevinskih projekata.

4.3. Model predviđanja prekoračenja ugovorenog iznosa

Analiza višestruke studije slučaja potvrđuje da odstupanja od ugovorenih troškova nisu rijetkost u građevinskim projektima. Pravodobno prepoznavanje rizika prekoračenja iznosa omogućuje dionicima kvalitetnije planiranje, upravljanje budžetom i smanjenje potencijalnih negativnih posljedica. U ovom dijelu prikazuju se rezultati razvijenog modela predviđanja prekoračenja ugovorenog iznosa. Model koristi metode strojnog učenja, a razvoj obuhvaća izbor značajki koje najviše doprinose točnosti predviđanja, optimizaciju arhitekture neuronske mreže i testiranje kombinacija hiperparametara.

4.3.1. Odabir značajki i inicijalna optimizacija modela predviđanja prekoračenja ugovorenog iznosa

Razvoj modela predviđanja prekoračenja ugovorenog iznosa temelji se na pažljivom odabiru značajki s najvećim utjecajem na točnost predviđanja i postupnoj optimizaciji arhitekture i hiperparametara neuronske mreže. U skladu s procesom razvoja prikazanom u potpoglavlju 3.2.2., značajke se biraju prema njihovoj relativnoj važnosti. Tablica 25 prikazuje optimalne arhitekture i hiperparametri modela za svaku kombinaciju broja značajki, rangirane prema najmanjoj vrijednosti MSE. Za svaku kombinaciju značajki prikazuje se model s najboljim metrikama. Rezultati pokazuju da gotovo svi modeli imaju niske vrijednosti R^2 , a u nekim slučajevima čak i negativne vrijednosti. Takvi rezultati upućuju na ozbiljne probleme s generalizacijom modela.

Tablica 25. Pregled optimalnih kombinacija broja značajki i arhitekture mreže s pripadajućim performansama (model predviđanja prekoračenja ugovorenog iznosa)


Broj značajki	Broj skrivenih slojeva	Broj neurona (1.sloj)	Broj neurona (2.sloj)	Ispuštanje neurona (1.sloj)	Ispuštanje neurona (2.sloj)	Stopa učenja	Aktivacijska funkcija	MSE	RMSE	MAE	SMAPE	R ²
3	1	20		0		0,001	relu	0,0336	0,1677	0,1299	110,98	0,4714
7	2	18	10	0,2	0	0,001	relu	0,0375	0,1926	0,1558	109,47	-0,0651
8	1	16		0,2		0,005	relu	0,0397	0,1945	0,1470	123,61	0,0663
4	1	8		0,3		0,005	relu	0,0420	0,1988	0,1497	122,19	0,0953
5	1	16		0,3		0,001	relu	0,0428	0,2045	0,1574	119,02	-0,3372
6	1	32		0		0,001	relu	0,0436	0,2002	0,1526	114,84	0,1088
19	1	40		0		0,001	tanh	0,0452	0,2119	0,1633	117,31	-0,4182
11	1	40		0,1		0,001	tanh	0,0456	0,2126	0,1669	107,70	-0,2580
9	2	16	16	0	0,3	0,005	relu	0,0495	0,2013	0,1402	110,04	0,2518
13	2	40	8	0	0	0,001	tanh	0,0497	0,2226	0,1835	124,48	-0,4227
12	1	24		0		0,010	relu	0,0503	0,2188	0,1501	105,01	-0,2106
14	2	16	8	0,1	0	0,005	tanh	0,0505	0,2213	0,1534	115,23	-0,2851
18	1	40		0		0,010	relu	0,0529	0,2197	0,1628	125,00	-0,0338
21	1	32		0		0,010	relu	0,0529	0,2254	0,1588	112,07	-0,2447
16	1	32		0,3		0,001	tanh	0,0560	0,2366	0,1869	111,94	-0,7280
22	1	32		0,3		0,010	relu	0,0568	0,2264	0,1662	115,44	-0,0815
20	2	12	12	0	0	0,010	relu	0,0569	0,2160	0,1598	122,02	0,0959
10	2	16	16	0	0	0,001	relu	0,0591	0,2395	0,1808	131,47	-0,5128
15	1	40		0,2		0,005	relu	0,0622	0,2478	0,1839	134,66	-0,8864
17	2	16	16	0,1	0	0,010	relu	0,0632	0,2342	0,1639	121,43	-0,1034

Negativan R^2 znači da model ne predviđa bolje od srednje vrijednosti ciljane varijable i da ne uspijeva učiti smislene obrasce iz podataka. Opći trend pokazuje da povećanje broja značajki ne rezultira nužno poboljšanjem performansi, već često dovodi do povećanja vrijednosti MSE, negativnih vrijednosti R^2 i potencijalno prekomjernog prilagođavanja modela trening podacima. Većina modela koristi ReLU aktivacijsku funkciju. Dodavanje regularizacije u ovoj fazi ne poboljšava performanse modela. Štoviše, ispuštanje neurona ima negativan utjecaj u gotovo svim slučajevima.


Model s tri značajke i jednim skrivenim slojem s 20 neurona ostvaruje najniži MSE (0,0336) i najveći R^2 (0,4714). Međutim, vrlo visoka vrijednost SMAPE (110,98 %) ukazuje na velika odstupanja između predviđenih i stvarnih vrijednosti. Model sa sedam značajki i dva skrivena sloja (18 i 10 neurona) ostvaruje nešto viši MSE (0,0375), ali bilježi negativan R^2 (-0,0651). Negativna vrijednost R^2 upućuje na nisku pouzdanost i ograničenu sposobnost modela za precizno predviđanje.

Dodatni uvid u ponašanje modela pruža analiza gubitka kroz epohe. Graf gubitka za model s 3 značajke (slika 27) prikazuje stabilan i kontinuiran pad vrijednosti MSE, bez značajnih oscilacija. Krivulja pokazuje glatku konvergenciju te, na prvi pogled, sugerira da model učinkovito uči iz podataka bez znakova prekomjernog prilagođavanja.

Međutim, glatka konvergencija može ukazivati i na ograničeno prepoznavanje složenijih obrazaca jer model uči iz malog broja značajki. Graf gubitka za model sa 7 značajki (slika 28) pokazuje izražene oscilacije. Nagli skokovi u gubicima mogu biti posljedica šuma u podacima, neadekvatnog prilagođavanja težina ili činjenice da optimizacija nije odabrala najučinkovitije kombinacije hiperparametara. Oscilacije upućuju na nestabilnost modela u predviđanju, ali istovremeno pokazuju osjetljivost na složenije obrasce u podacima i otvara prostor za unaprjeđenje performansi kroz daljnju optimizaciju.



Slika 27. Gubitak kroz epohe za neuronsku mrežu s 3 značajke (model predviđanja prekoračenja ugovorenog iznosa)



Slika 28. Gubitak kroz epohe za neuronsku mrežu sa 7 značajki (model predviđanja prekoračenja ugovorenog iznosa)

Tablica 26 prikazuje značajne razlike u performansama modela s 3 i 7 značajki. Iako model s 3 značajke i jednostavnijom arhitekturom postiže niže vrijednosti MSE, RMSE, MAE i SMAPE u usporedbi s modelom sa 7 značajki, njegova vrijednost R^2 je i dalje niska, što ukazuje na ograničenu sposobnost objašnjavanja varijabilnosti ciljne varijable. Model sa 7 značajki ima negativnu vrijednost R^2 te pokazuje ograničenu sposobnost modela da objasni ciljnu varijablu.


Tablica 26. Usporedba performansi modela neuronske mreže s 3 i 7 značajki (model predviđanja prekoračenja iznosa)

Metrika	Model s 3 značajke	Model sa 7 značajki
MSE	0,0154	0,0440
RMSE	0,1241	0,2098
MAE	0,0885	0,1562
SMAPE	59,17 %	67,02 %
R^2	0,3023	-0,9946

Model s 3 značajke može imati niže vrijednosti pogreški, ne nužno zato što ima točnija predviđaja, već zato što je pojednostavljen do te mjere da ne uzima u obzir važne značajke koje utječu na prekoračenje ugovorenog iznosa. Model sa 7 značajki obuhvaća širi spektar informacija i ima veći kapacitet za prepoznavanje relevantnih informacija. Osim toga, koristi kompleksniju arhitekturu i pruža veću fleksibilnost u učenju nelinearnih odnosa među značajkama. Dodatan argument za njegov odabir je mogućnost poboljšanja kroz optimizaciju hiperparametara. Trenutne oscilacije u procesu učenja upućuju da postojeća kombinacija još nije optimalna, ali i da nije


iscrpila puni potencijal modela. S obzirom na sve navedeno, za dodatnu optimizaciju odabire se model sa 7 značajki.

Analiza stvarnih i predviđenih vrijednosti (slika 29) potvrđuje izražene oscilacije u predviđanjima. Primjećuju se značajna odstupanja gdje model u nekim slučajevima značajno precjenjuje ili podcjenjuje stvarne vrijednosti bez jasnog uzorka. Primjerice, za stvarnu vrijednost od 0,3730, model predviđa samo 0,0270, dok u drugom slučaju gotovo ista stvarna vrijednost rezultira još nižim predviđanjem od -0,0621. Oscilacije sugeriraju da model nije u stanju dosljedno prepoznati obrasce među značajkama, što dodatno potvrđuje negativan R^2 i visoka vrijednost SMAPE u unakrsnoj validaciji.



Slika 29. Usporedba stvarnih i predviđenih vrijednosti nakon optimizacije (model predviđanja prekoračenja ugovorenog iznosa)

Slika 30 prikazuje analizu važnosti značajki kako bi se utvrdilo koje značajke najviše utječu na prekoračenje ugovorenog iznosa.



Slika 30. Relativna važnost pojedinih značajki u modelu predviđanja prekoračenja ugovorenog iznosa

Analiza važnosti značajki pokazuje da je analiza dinamičkog plana najznačajniji faktor u predviđanju prekoračenja ugovorenog iznosa, s relativnom važnošću od 57,02 %. Isti pokazatelj se identificira najvažnijim i u modelu predviđanja prekoračenja ugovorenog trajanja, što je očekivano, jer promjene u dinamičkom planu često imaju izravan utjecaj na konačne ishode projekta. Analiza dinamičkog plana predstavlja realizaciju aktivnosti, njihovu međusobnu povezanost te uključuje naplaćene nepredviđene, naknadne i dodatne radove koji povećavaju ukupni trošak projekta u odnosu na inicijalno ugovoreni iznos. Sljedeće dvije najvažnije značajke su vrsta ugovora (ugovor o gradnji) s udjelom od 18,64 % te ugovorena vrijednost radova s 5,27 %. Trend promjena i dodatnih radova (4,68 %) ukazuje da povećanje obujma radova tijekom projekta može značajno utjecati na iznose projekta. Tip projekta visokogradnja (3,18 %) također ima utjecaj, budući da su projekti visokogradnje složeniji i podložniji potencijalnim tehničkim izazovima. Kvaliteta projektne dokumentacije (2,32 %) i zadovoljstvo sudionika (1,80 %) dodatno potvrđuju važnost ne samo tehničkih i financijskih, već i organizacijskih i komunikacijskih čimbenika u kontroli troškova.


Rezultati pokazuju da trenutačna verzija modela nije optimalna za predviđanje prekoračenja ugovorenog iznosa. Ključni identificirani problemi uključuju negativan R^2 , izrazito visoke vrijednosti SMAPE i nekonzistentna predviđanja. Iako model s 3 značajke ostvaruje bolje metrike, ne obuhvaća sve važne obrasce. Model sa 7 značajki pokazuje veći potencijal za učenje, unatoč lošijim inicijalnim rezultatima. Daljnja optimizacija modela otvara mogućnosti poboljšanja točnosti i stabilnosti rezultata.

4.3.2. Dodatna optimizacija hiperparametara i analiza performansi modela predviđanja prekoračenja ugovorenog iznosa

Kako bi se poboljšala točnost modela i smanjila pogreška u predviđanju, provodi se dodatna optimizacija hiperparametara. Proces uključuje testiranje različitih kombinacija ključnih hiperparametara, uključujući stopu učenja, ispuštanje neurona, optimizatore i aktivacijske funkcije, s ciljem pronalaska optimalne arhitekture neuronske mreže koja ostvaruje najbolju točnost u predviđanju. Prethodno provedene analize ukazuju na nekoliko problema u inicijalnoj optimizaciji modela, pri čemu se posebno ističe negativna vrijednost R^2 i visoke oscilacije u predviđanjima. Model ne uspijeva pravilno prepoznati obrasce među značajkama, što dovodi do nekonzistentnih i nepouzdatih predviđanja.

Jedan od glavnih razloga za narušenu pouzdanost modela je neuravnotežena distribucija podataka, pri čemu su vrijednosti ciljne varijable koncentrirane u užem rasponu, a ekstremne vrijednosti slabo zastupljene. Model je skloniji predviđanju dominantnih vrijednosti, dok su predviđanja za rjeđe slučajeve značajno manje točne. Kako bi se riješio problem, primijenjuje se SMOGN. Slika 31 prikazuje distribuciju ciljne

varijable prije i nakon njene primjene. Rezultati pokazuju ravnomjerniju raspodjelu, čime je osigurana bolja pokrivenost svih vrijednosti ciljne varijable. Poboljšana distribucija ciljne varijable omogućuje modelu da bolje uči iz podataka i preciznije generalizira predviđanja, osobito u dijelovima distribucije koji su prethodno bili slabo zastupljeni.




Slika 31. Distribucija ciljne varijable prije i poslije SMOGN

Rezultati dodatne optimizacije pokazuju su da najbolji model ima stopu učenja 0,005, optimizator SGD s momentom 0,9, aktivacijsku funkciju elu i ispuštanje neurona od 5 %. Optimizirani model ostvaruje najnižu vrijednost MSE (0,0011) i upućuje na najmanju ukupnu pogrešku u predviđanjima te najvišu vrijednost koeficijenta determinacije (0,9081), koja je značajno viša od inicijalnog modela. Uspješnost optimizacije dodatno se potvrđuje analizom performansi na skupu za treniranje i testiranje (tablica 27). Analiza metrika pokazuje stabilne performanse između skupa za treniranje i testiranje, čime je smanjena mogućnost prekomjernog prilagođavanja modela. Iako je SMAPE nešto viši na testnom skupu, ukupni rezultati potvrđuju da je model sada precizniji i sposobniji za generalizaciju. Stabilnost performansi između skupova sugerira da model uspješno prepoznaje obrasce u podatcima bez prekomjernog prilagođavanja.

Tablica 27. Usporedba performansi na skupu za treniranje i testiranje (model predviđanja prekoračenja ugovorenog iznosa)

Metrika	Skup za treniranje	Skup za testiranje
MSE	0,0112	0,0011
RMSE	0,1060	0,0336
MAE	0,0698	0,0255
SMAPE	18,91 %	27,52 %
R ²	0,8259	0,9081

Dodatno poboljšanje modela u odnosu na inicijalni model potvrđuje analiza gubitka kroz epohe. Slika 32 prikazuje izražen trend smanjenja gubitka, uz naglašen pad pogreške u ranim fazama treniranja. Takav obrazac upućuje na učinkovito učenje modela i brzu konvergenciju prema optimalnom rješenju. Nakon približno 20 epoha, gubitak se stabilizira. Izostanak značajnih oscilacija dodatno potvrđuje da model nije prekomjerno prilagođen.




Slika 32. Gubitak modela predviđanja prekoračenja ugovorenog iznosa (nakon dodatne optimizacije)

Analiza usporedbe stvarnih i predviđenih vrijednosti pokazuje da model sada značajno bolje prati ciljne vrijednosti (tablica 28 i slika 33). Iako i dalje postoje manja odstupanja, posebice kod ekstremnih vrijednosti, ona su sada značajno smanjena u odnosu na inicijalni model.

Tablica 28. Usporedba stvarnih vrijednosti i predviđenih vrijednosti (model predviđanja prekoračenja ugovorenog iznosa)


Primjer	Stvarna vrijednost	Predviđena vrijednost nakon dodatne optimizacije
1	0,0208	0,0002
2	0,0462	0,0786
3	0,1710	0,1801
4	0,2266	0,1884
5	0,0974	0,1008
6	-0,0017	-0,0099
7	0,3759	0,4445
8	0,1261	0,1478
9	0,0462	0,0301

Primjerice, model preciznije predviđa negativne vrijednosti. Za stvarnu vrijednost -0,0017 predviđena vrijednost iznosi -0,0099, dok za vrijednost 0,3759 predviđanje iznosi 0,4445. Takav rezultat predstavlja značajno poboljšanje u odnosu na prethodnu verziju modela. Usporedba s ranijim predviđanjima nije moguća jer je primjena SMOGN promijenila skup podataka.



Slika 33. Usporedba stvarnih i predviđenih vrijednosti nakon dodatne optimizacije (model predviđanja prekoračenja ugovorenog iznosa)


Dijagram raspršenja (slika 34) prikazuje odnos između stvarnih i predviđenih vrijednosti te omogućuje vizualnu procjenu preciznosti modela. Većina točaka nalazi se u donjem lijevom kvadrantu grafa, što je u skladu s činjenicom da većina stvarnih vrijednosti ima niske iznose. Predviđene vrijednosti većinom se grupiraju uz crvenu liniju koja označava idealno predviđanje, uz izraženija odstupanja pri višim stvarnim vrijednostima.



Slika 34. Dijagram raspršenja stvarnih i predviđenih vrijednosti (model predviđanja prekoračenja ugovorenog iznosa)


U tom rasponu model povremeno podcjenjuje ili precjenjuje rezultate, što upućuje na veću varijabilnost u predviđanju ekstremnih vrijednosti. Ipak, ukupna raspodjela točaka ne pokazuje prisutnost sistemske pristranosti i sugerira da model uspješno prepoznaje i generalizira obrasce iz podataka.

Analiza reziduala (slika 35) pruža uvid u strukturu i raspodjelu grešaka modela, odnosno razlike između stvarnih i predviđenih vrijednosti. U idealnom slučaju, reziduali bi trebali biti ravnomjerno raspoređeni oko idealne linije, bez vidljivog obrasca koji bi ukazivao na pristranost. Na prikazanom grafu većina reziduala koncentrirana je oko nule, osobito za niže predviđene vrijednosti, dok su odstupanja izraženija pri višim vrijednostima. Uočena raspodjela reziduala može ukazivati na nešto veću varijabilnost modela u predviđanju ekstremnih vrijednosti. S obzirom da su reziduali u skupu za treniranje i testiranje raspoređeni na sličan način, zaključuje se da model generalizira dosljedno i da nema značajnih razlika u bilo kojem skupu podataka.



Slika 35. Reziduali modela (model predviđanja prekoračenja ugovorenog iznosa)

Kutijasti dijagram (slika 36) i pripadajuća analiza statističkih pokazatelja distribucije (tablica 29) prikazuju raspon pogrešaka u skupu za treniranje i testiranje. Skup za treniranje pokazuje nešto širi interkvartilni raspon u odnosu na skup za testiranje, što ukazuje na veću varijabilnost grešaka tijekom treniranja modela. Dulji brkovi u skupu za treniranje te prisutnost istaknutih odstupanja sugeriraju da model ima izazove u učenju specifičnih primjera. Medijani grešaka u oba skupa nalaze se blizu nule, čime se potvrđuje da model nije pristran u svojim predviđanjima. Standardna devijacija je viša u skupu za treniranje nego u skupu za testiranje, što je očekivano budući da model uči na većem rasponu podataka.



Slika 36. Kutijasti dijagram grešaka predviđanja (model predviđanja prekoračenja ugovorenog iznosa)

Analiza asimetrije distribucije grešaka pokazuje gotovo simetričnu raspodjelu u skupu za treniranje, dok skup za testiranje ima blagu negativnu asimetriju. To znači da model u nekim slučajevima može podcijeniti stvarne vrijednosti, no odstupanje je minimalno i ne utječe značajno na ukupnu točnost predviđanja. Spljoštenost distribucije ukazuje na izraženiju šiljatost u skupu za treniranje, dok su greške u testnom skupu ravnomjernije raspoređene, što dodatno potvrđuje stabilnost modela.

Tablica 29. Statistički pokazatelji (model predviđanja prekoračenja ugovorenog iznosa)

Statistički pokazatelj	Skup za treniranje	Skup za testiranje
Srednja vrijednost greške	-0,0147	-0,0070
Medijan greške	-0,0076	0,0034
Standardna devijacija	0,1131	0,0348
Asimetrija distribucije	0,0121	-0,8352
Spljoštenost distribucije	1,0621	0,1185
Interkvartilni raspon	0,0542	0,0378

Dodatna optimizacija hiperparametara značajno poboljšava performanse modela, smanjuje pogreške predviđanja i povećava točnost. Analiza distribucije podataka, analiza grešaka i vizualizacije potvrđuju da model dosljedno ostvaruje stabilne rezultate bez izraženih znakova prekomjernog prilagođavanja. Na temelju svih analiziranih pokazatelja može se zaključiti da razvijeni model pruža najbolju moguću ravnotežu između preciznosti i generalizacije. Iako je prije praktične primjene nužna

dodatna validacija, dosadašnji rezultati ukazuju na pouzdanu sposobnost predviđanja modela, uz stabilno ponašanje i niske pogreške.

4.3.3. Unakrsna validacija modela predviđanja prekoračenja ugovorenog iznosa

Kako bi se potvrdila stabilnost i pouzdanost neuronske mreže, model je podvrgnut unakrsnoj validaciji s tri skupa. Unakrsna validacija omogućava detaljniju procjenu modela testiranjem na različitim podskupovima podataka i osigurava da model nije previše prilagođen specifičnom skupu podataka, već da može generalizirati na nove i neviđene podatke. Rezultati (tablica 30) pokazuju stabilne performanse modela, uz konzistentne metrike između različitih skupova. Analiza prosječnih vrijednosti metrika potvrđuje da model ostvaruje nisku pogrešku i stabilna predviđanja. MSE se kreće u rasponu od 0,0060 do 0,0169, s prosječnom vrijednošću od 0,0111. Navedene vrijednosti ukazuju na nisku ukupnu pogrešku modela. RMSE, koji omogućuje intuitivniju procjenu preciznosti predviđanja, u prosjeku iznosi 0,1032 i potvrđuje da model ostvaruje mala odstupanja od stvarnih vrijednosti. Prosječna vrijednost MAE iznosi 0,0745 i ukazuje na dosljedna predviđanja s relativno malim odstupanjima. SMAPE se kreće između 14,02 % i 40,08 %. Prosječna vrijednost iznosi 28,81 % i ostaje unutar prihvatljivih granica, uz nešto veću varijabilnost među skupovima. R^2 u rasponu od 0,7731 do 0,8468 potvrđuje da model objašnjava značajan dio varijacija u podacima.

Tablica 30. Rezultati metrika unakrsne validacije (3 skupa modela predviđanja prekoračenja ugovorenog iznosa)

Skup	MSE	RMSE	MAE	SMAPE	R2
Skup 1	0,0105	0,1026	0,0725	32,34 %	0,7731
Skup 2	0,0060	0,0772	0,0557	14,02 %	0,8468
Skup 3	0,0169	0,1298	0,0952	40,08 %	0,7854
Prosjek:	0,0111	0,1032	0,0745	28,81 %	0,8018

Prosječne vrijednosti metrika ukazuju na stabilne performanse modela i njegovu sposobnost generalizacije na različite podjele podataka te potvrđuju primjenjivost u realnim uvjetima.

4.4. Rasprava o modelima predviđanja prekoračenja ugovorenih trajanja i iznosa

Ovo poglavlje prikazuje performanse razvijenog modela i uspoređuje ih s postojećim modelima iz literature. Dosadašnja istraživanja potvrđuju važnost odabira odgovarajućih značajki i optimizacije modela za postizanje visoke točnosti. Unatoč ograničenoj veličini baze podataka, analiza u tri vremenske točke i prilagodba podataka doprinijele su stabilnosti i pouzdanosti rezultata modela.

Regresijski modeli se često koriste za predviđanje prekoračenja iznosa u građevinskim projektima, no pokazuju ograničenja u obuhvaćanju složenih odnosa među značajkama. Primjerice, Senouci i dr. (2016) koriste regresijsku analizu i postižu R^2 od 0,6943 za visokogradnju i 0,6677 za projekte odvodnje. S druge strane, složeniji modeli poput neizrazite logike i potpornih vektora pokazuju višu točnost, ali uz veću računalnu složenost. Obianyo i dr. (2022) koriste neizrazitu logiku za analizu faktora prekoračenja troškova i postižu RMSE od 0,321 i R^2 od 0,995. Slično tome, Coffie i Cudjoe (2023) primijenjuju model potpornih vektora, koji rezultira s R^2 od 0,99, RMSE od 0,099 i MAPE od 27,8 % te se pokazuje kao visoko točan alat za predviđanje. Najnovija istraživanja potvrđuju prednosti primjene naprednih modela strojnog učenja poput XGBoosta. Coffie i Cudjoe (2024) koriste XGBoost za analizu povijesnih podataka o građevinskim projektima te razvijaju model predviđanja prekoračenja troškova s RMSE od 0,202, MSE od 0,041 i MAE od 0,069. Usporedbom s navedenim istraživanjima, predloženi model neuronske mreže za predviđanje prekoračenja ugovorenog iznosa pokazuje konkurentne ili bolje performanse uz manju računalnu složenost i veću interpretabilnost. Model ostvaruje R^2 od 0,9081 na testnom skupu, što je značajno bolje od regresijskih modela te usporedivo sa složenijim modelima poput modela potpornih vektora i neizrazite logike. MSE od 0,0011, RMSE od 0,0336 i MAE od 0,0255 su niži od vrijednosti koje postižu autori korištenjem neizrazite logike, modela potpornih vektora i XGBoost. Osim toga, provedena unakrsna validacija na 3 skupa potvrđuje robusnost modela sa stabilnim prosječnim metrikama te ukazuje na dobru generalizacijsku sposobnost i smanjeni rizik od prekomjernog prilagođavanja skupu podataka.

Što se tiče modela predviđanja prekoračenja ugovorenog trajanja građevinskih projekata, dostupna literatura dosljedno potvrđuje ograničenja regresijskih pristupa, osobito kada je riječ o modeliranju nelinearnih odnosa između ulaznih značajki i ciljne varijable. Primjerice, Petruseva i dr. (2012) koriste linearnu regresiju koja ostvaruje koeficijent determinacije R^2 od 0,733 i RMSE od 0,520, dok neuronska mreža u istom istraživanju značajno nadmašuje te rezultate metrikama R^2 od 0,970, MAE od 0,113 i RMSE od 0,162. Rezultati potvrđuju da složeniji modeli strojnog učenja bolje prepoznaju obrasce u podacima i daju preciznija predviđanja. Slično tome, Trijeti i dr.

(2023) primijenjuju umjetne neuronske mreže za predviđanje trajanja građevinskih projekata te postižu MAE od 0,2044 i RMSE od 0,6618. Al Mnaseer i dr. (2023) analiziraju projekte u Jordanu koristeći isti pristup, gdje neuronska mreža ostvaruje R^2 od 0,9385, RMSE od 4,659, MSE od 21,709 i MAE od 0,8590. Nadalje, Velumani i dr. (2021) uspoređuju više modela predviđanja trajanja, pri čemu neuronska mreža ostvaruje najbolje rezultate s MSE od 0,03 i RMSE od 0,17, dok tradicionalniji modeli, poput Bromilowovog, postižu znatno slabije performanse (MSE od 0,28 i RMSE od 0,53). Usporedbom s navedenim istraživanjima, predloženi model neuronske mreže za predviđanje prekoračenja ugovorenog trajanja pokazuje konkurentne ili bolje performanse. Razvijeni model postiže MSE od 0,0029, RMSE od 0,0536, MAE od 0,0435, SMAPE od 32,32 % i R^2 od 0,9497. Metrike ukazuju na visoku točnost predviđanja i sposobnost modela da objasni gotovo 95 % varijance u stvarnim vrijednostima.

U konačnici, ovi nalazi potvrđuju hipotezu H2. Odabir relevantnih ulaznih značajki uz optimizaciju arhitekture i hiperparametara modela značajno doprinosi točnosti predviđanja. Konkretno, provedene analize potvrđuju da integracija tehničkih, organizacijskih, financijskih i interpersonalnih čimbenika omogućuje bolju reprezentaciju stvarnih uvjeta projekta, što rezultira nižim vrijednostima pogrešaka i većom stabilnošću predviđanja modela. Osim toga, usporedba s rezultatima iz literature naglašava konkurentne prednosti predloženog modela, posebice u pogledu robusnosti i interpretabilnosti. Nalazi ukazuju na potrebu za holističkim pristupom u razvoju modela predviđanja u građevinskom sektoru, pri čemu se preporučuje uključivanje šireg spektra značajki i korištenje naprednih algoritama strojnog učenja. U konačnici, potvrda hipoteze H2 dodatno podupire važnost prilagodbe modela specifičnostima dostupnih podataka i stvarnim okolnostima projekata, čime se doprinosi razvoju pouzdanih i primjenjivih alata za upravljanje rizicima prekoračenja u građevinskoj praksi.

4.5. Model predviđanja krivulje kumulativnog napretka

U cilju pronalaska najpouzdanijeg pristupa, analizira se sposobnost različitih modela u predviđanju krivulje kumulativnog napretka građevinskih projekata. Precizno modeliranje napretka ključno je za učinkovitu kontrolu i upravljanje tijekom izvedbe. S obzirom na sve izraženiju potrebu za dinamičnim i prilagodljivim alatima u planiranju i nadzoru građevinskih aktivnosti, pouzdano predviđanje tijeka financijskog i vremenskog napretka postaje iznimno važno za sve ključne dionike.


U ovom potpoglavlju prikazuje se usporedba rezultata tradicionalnih matematičkih modela s novorazvijenim modelom temeljenim na neuronskoj mreži. Cilj analize je utvrditi koji pristup osigurava veću točnost i fleksibilnost u predviđanju krivulje

kumulativnog napretka tijekom trajanja projekta. U nastavku su prikazani rezultati za pojedine modele, uz detaljnu analizu njihove preciznosti i ograničenja, čime se doprinosi ostvarenju petog pomoćnog cilja istraživanja.

4.5.1. Matematički modeli predviđanja krivulje kumulativnog napretka

U skladu s metodološkim pristupom opisanim u potpoglavlju 3.3.1., nakon kategorizacije podataka prema vrijednosti i tipu projekta, testiraju se različiti matematički modeli s ciljem identifikacije onih koji najbolje opisuju oblik krivulje kumulativnog napretka u različitim kontekstima građevinskih projekata. Za svaku definiranu kategoriju i potkategoriju baze podataka (cjelokupni skup, podjela prema vrijednosti i prema tipu projekta) izrađuje se vizualizacija krivulja kumulativnog napretka. Cilj grafova je omogućiti vizualnu procjenu stupnja podudarnosti između predviđenih i stvarnih vrijednosti, kao i otkrivanje potencijalnih obrazaca odstupanja.

Slika 37 prikazuje krivulje triju matematičkih modela (polinom 4. stupnja, beta distribucija i Rayleighova distribucija) koji su za cjelokupnu bazu podataka ostvarili najbolje metrike. Grafički prikaz jasno ilustrira njihovu sposobnost prilagodbe stvarnim vrijednostima i vizualizira razlike u točnosti.



Slika 37. Krivulje kumulativnog napretka najboljih matematičkih modela (cjelokupna baza podataka)

Tablica 31 prikazuje rezultate kvantitativne analize i obuhvaća izraze optimalnih modela po kategorijama (detaljni izrazi navedeni su u potpoglavlju 3.3.1.), zajedno s pripadajućim evaluacijskim metrikama. Metrike omogućuju višedimenzionalnu procjenu točnosti modela, pri čemu se naglasak stavlja na njihovu robusnost, interpretabilnost i primjenjivost u praksi. Analizom performansi modela omogućuje se

identifikacija njihovih prednosti i ograničenja, osobito u kontekstu usporedbe tradicionalnih pristupa s naprednijim tehnikama.

Tablica 31. Pregled performansi matematičkih modela prema kategorijama

Kategorizacija		Izraz	MAE	MSE	SMAPE	RMSE	R ²
Cjelokupna baza podataka		(3)	0,059	0,005	26,28 %	0,074	0,9466
Vrijednost projekta	< 10 milijuna eura	(8)	0,058	0,005	26,78 %	0,073	0,9528
	> 10 milijuna eura	(4)	0,056	0,005	26,50 %	0,073	0,9442
Tip projekta	komunalna infrastruktura	(6)	0,038	0,002	18,09 %	0,047	0,9731
	cestovna infrastruktura	(8)	0,064	0,006	31,56 %	0,080	0,9435
	visokogradnja	(6)	0,050	0,005	20,25 %	0,070	0,9518

Rezultati pokazuju niske vrijednosti pogrešaka. Svi koeficijenti determinacije veći su od 0,94, što ukazuje na vrlo dobru prilagodbu modela podatcima. Međutim, detaljna analiza otkriva određene razlike među pristupima.

Model razvijen na cjelokupnoj bazi podataka pokazuje zadovoljavajuće performanse, a njegova prednost leži u jednostavnosti i većem broju dostupnih podataka. Ipak, model treniran na svim dostupnim podatcima pokazuje nešto slabije rezultate u gotovo svim metrikama u odnosu na modele razvijene unutar kategoriziranih skupova. Rezultati sugeriraju da korištenje jedinstvenog modela za sve podatke može prikriti specifične obrasce prisutne unutar pojedinih kategorija.


Kategorizacija prema vrijednosti projekta donosi nešto bolje rezultate u potkategorijama. Obje potkategorije (ispod i iznad 10 milijuna eura) ostvaruju slične i konzistentne rezultate, što sugerira da takva kategorizacija doprinosi boljoj reprezentaciji pojedinih skupina projekata. Iako ne donosi najniže vrijednosti pogrešaka, kategorizacija prema vrijednosti projekta pokazuje ravnotežu između točnosti i robusnosti modela, uz zadržavanje visokog stupnja interpretabilnosti i fleksibilnosti u primjeni.

Kategorizacija prema tipu projekta pokazuje veću varijabilnost među potkategorijama. Najbolje rezultate postiže potkategorija komunalne infrastrukture, dok modeli za cestovnu infrastrukturu pokazuju najslabije performanse u ovoj kategoriji. Visokogradnja se nalazi između navedena dva ekstrema. Kod komunalne infrastrukture i visokogradnje, modeli polinoma četvrtog stupnja pokazuju visoku točnost, ali vizualizacije ukazuju na prekomjerne oscilacije u obliku krivulje. Zbog toga se kao optimalan model odabire Gompertzova funkcija, koja nudi uravnoteženiji oblik predviđanja i smanjenje oscilacija.

Iako nijedna kategorizacija nije univerzalno superiorna u svim metrikama, kategorizacija prema vrijednosti projekta pokazuje se najstabilnijom i


najuravnoteženijom u pogledu točnosti, interpretabilnosti i konzistentnosti. Kategorizacija prema vrijednosti projekta odabire se kao najprikladnija za daljnju usporedbu s modelom temeljenim na neuronskoj mreži.

Kako bi se dodatno procijenila učinkovitost matematičkog modela u okviru izabrane kategorizacije, provodi se vizualna analiza predviđenih i stvarnih vrijednosti, kao i distribucije pogrešaka (reziduala). Slika 38 prikazuje odnos između stvarnih i predviđenih vrijednosti za obje vrijednosne potkategorije. Većina podataka prati dijagonalnu crvenu liniju i ukazuje na dobru preciznost. Veća raspršenost vidljiva je u potkategoriji vrijednosti manjih od 10 milijuna eura, posebno kod manjih stvarnih vrijednosti, dok su predviđanja za projekte iznad 10 milijuna eura znatno preciznija. Sveukupno, model bolje predviđa veće vrijednosti ugovora nego manje.




Slika 38. Dijagram raspršenja stvarnih i predviđenih vrijednosti: a) vrijednost projekta manja od 10 milijuna eura; b) vrijednost projekta veća od 10 milijuna eura

Slika 39 predstavlja vizualizaciju reziduala u odnosu na predviđene vrijednosti te ukazuje na potrebu za poboljšanjem modela. Za vrijednosti projekta manje od 10 milijuna eura uočava se zakrivljen uzorak, dok su kod većih projekata reziduali ravnomjernije raspoređeni, ali su oscilacije i dalje prisutne. Rezultati sugeriraju da model ima određene sistematske greške.



Slika 39. Režidualni grafovi: a) vrijednost projekta manja od 10 milijuna eura; b) vrijednost projekta veća od 10 milijuna eura

Slika 40 prikazuje distribuciju grešaka po potkategorijama. Na grafu potkategorije vrijednosti projekta manje od 10 milijuna eura vidljivo je da su reziduali blago asimetrični. Većina vrijednosti je koncentrirana oko nule uz nekoliko većih odstupanja. Desni graf, za vrijednosti projekata veće od 10 milijuna eura, pokazuje sličnu raspodjelu, no reziduali su nešto više nagnuti prema negativnim vrijednostima, što sugerira blagu pristranost u predviđanjima.



Slika 40. Distribucija grešaka: a) vrijednost projekta manja od 10 milijuna eura; b) vrijednost projekta veća od 10 milijuna eura

Na temelju provedenih analiza može se zaključiti da matematički modeli pružaju pouzdanu osnovu za predviđanje krivulje kumulativnog napretka, osobito kada se primjenjuje kategorizacija prema vrijednosti projekta. Ipak, uočene oscilacije i sistemske greške u nekim segmentima ukazuju na potrebu za fleksibilnijim pristupima. U nastavku se stoga analizira model temeljen na neuronskoj mreži, s ciljem procjene njegove sposobnosti da preciznije obuhvati nelinearne obrasce i smanji pogreške predviđanja.

4.5.2. Model neuronske mreže za predviđanje krivulje kumulativnog napretka

Nakon opsežne optimizacije hiperparametara i arhitekture mreže odabire se kombinacija koja ostvaruje najbolje performanse na validacijskom skupu. Najbolje rezultate postiže model s dva skrivena sloja od po 32 neurona, ReLU aktivacijskom funkcijom i stopom učenja od 0,005, pri čemu regularizacija putem ispuštanja neurona nije korištena. Podjela podataka provodi se u omjeru 64:16:20, čime je osigurana ravnoteža između dostatne količine podataka za treniranje (204 uzorka), validaciju (51 uzorak) i testiranje (64 uzorka). Ovakva podjela omogućuje detaljnu procjenu performansi i sposobnosti generalizacije modela.


Tablica 32 prikazuje rezultate evaluacijskih metrika za sve skupove. Model ostvaruje niske vrijednosti MSE, RMSE i MAE na svim skupovima, uz minimalna odstupanja. Vrijednosti MAE gotovo su identične kroz sve skupove i ukazuju na visoku konzistentnost u predviđanjima. SMAPE je najniži na validacijskom skupu (14,79 %), a vrijednosti na skupu za treniranje (18,13 %) i testiranje (17,30 %) potvrđuje visoku točnost modela. Visoke vrijednosti koeficijenta determinacije R^2 (iznad 0,98) potvrđuju sposobnost modela da objasni varijaciju ciljne varijable. Sve navedeno upućuje da odabrani model neuronske mreže postiže visoku točnost i pokazuje robusnost bez znakova prekomjernog prilagođavanja.

Tablica 32. Usporedba performansi na skupu za treniranje, validaciju i testiranje (model predviđanja krivulje kumulativnog napretka)

Metrika	Skup za treniranje	Validacijski skup	Skup za testiranje
MAE	0,0302	0,0304	0,0291
MSE	0,0014	0,0015	0,0012
RMSE	0,0371	0,0381	0,0353
SMAPE	18,13 %	14,79 %	17,30 %
R^2	0,9866	0,9855	0,9877


Na temelju prikazanih numeričkih metrika zaključuje se da model pokazuje visoku razinu točnosti, stabilnosti i konzistentnosti u predviđanju kumulativnog napretka. Kako bi se dublje razumjela priroda pogrešaka, analizira se i vizualno ponašanje modela kroz analizu gubitka tijekom treniranja, odnosa stvarnih i predviđenih vrijednosti te distribucije reziduala. Vizualizacije omogućuju identifikaciju mogućih obrazaca pogrešaka, provjeru postojanja sistematskih odstupanja i potvrdu sposobnosti modela da generalizira na nove podatke. U nastavku su prikazani ključni grafovi koji dodatno potvrđuju kvantitativne nalaze i nude uvid u preciznost modela iz perspektive distribucije i raspodjele pogrešaka.

Vizualizacija gubitka tijekom treniranja i validacije (slika 41) prikazuje brzi pad funkcije gubitka tijekom prvih 10 epoha, što ukazuje na učinkovito učenje obrazaca iz podataka. Nakon 10. epohe, krivulje se stabiliziraju, a validacijski gubitak ostaje konstantan. Razlike između krivulje gubitka tijekom treninga i validacije su minimalne te sugeriraju da model dobro generalizira. Iako bi, s obzirom na stabilizaciju, bilo moguće skratiti trajanje treniranja na 15 epoha, broj epoha nije mijenjan s obzirom na nisku vremensku složenost procesa.




Slika 41. Gubitak tijekom treniranja i validacije

Dijagram raspršenja (slika 42) potvrđuje da model postiže visoku točnost. Točke su gusto raspoređene uz idealnu dijagonalu, uz tek manja odstupanja. Takva raspodjela potvrđuje dosljednost u predviđanjima i odsutnost izraženijih pogrešaka ili šuma.




Slika 42. Dijagram raspršenja stvarnih i predviđenih vrijednosti

Reziduali, definirani kao razlika između stvarnih i predviđenih vrijednosti, analiziraju se pomoću dijagrama raspršenja (slika 43). Reziduali su ravnomjerno raspoređeni s obje strane referentne crvene linije, bez uočljivog trenda, što sugerira odsutnost sistematskih grešaka.



Slika 43. Rezidualne vrijednosti modela predviđanja krivulje kumulativnog napretka


Histogram reziduala (slika 44) pokazuje da je većina grešaka koncentrirana oko nule i da nema značajne pristranosti u predviđanjima. Blaga asimetrija u desnu stranu ukazuje da model ponekad podcjenjuje stvarne vrijednosti. Desna strana ima izraženiji vrh oko 0,025. Lijeva strana je malo razvučenija, ali s manjim frekvencijama. Iako distribucija nije savršeno normalna, veličina grešaka je mala i ukazuje na dobra predviđanja.



Slika 44. Histogram reziduala

Kutijasti dijagram (slika 45 i tablica 33) potvrđuje da model nema značajnu pristranost u predviđanjima. Srednje vrijednosti i medijani pogrešaka nalaze se vrlo blizu nule te

potvrđuju da su predviđanja uravnotežena bez sistematskog precjenjivanja ili podcjenjivanja.



Slika 45. Kutijasti dijagram stvarnih i predviđenih vrijednosti

Standardna devijacija je nešto viša u skupu za testiranje nego u skupu za treniranje, što sugerira blago povećanu raspršenost predviđenih vrijednosti na novim podacima. Vrijednosti asimetrije pokazuju gotovo simetričan raspored grešaka u skupu za testiranje, dok su u skupu za treniranje nešto učestalije pozitivne greške. Spljoštenost distribucije ukazuje na veću koncentraciju grešaka oko srednje vrijednosti u skupu za treniranje, dok su u testnom skupu greške ravnomjernije raspoređene. Interkvartilni raspon potvrđuje nešto širu raspršenost grešaka u skupu za testiranje i upućuje na blagu varijabilnost bez narušavanja ukupne stabilnosti. Analiza kutijastog dijagrama i pripadajućih statističkih pokazatelja potvrđuje da model dobro generalizira obrasce podataka.

Tablica 33. Statistički pokazatelji (model predviđanja krivulje kumulativnog napretka)

Mjere	Skup za treniranje	Skup za testiranje
Srednja vrijednost greške	-0,0113	-0,0018
Medijan greške	-0,0145	0,0025
Standardna devijacija	0,0298	0,0413
Asimetrija distribucije	0,5409	-0,0182
Spljoštenost distribucije	1,0067	-0,6573
Interkvartilni raspon	0,0325	0,0531


Model pokazuje visok stupanj preciznosti i stabilnosti. Greške na krajevima distribucije nemaju značajan utjecaj na ukupne performanse modela. Budući da su ciljne varijable normalizirane i predstavljaju udjele naplaćenog iznosa od 0 do 1 na krivulji kumulativnog napretka, takva odstupanja mogu se smatrati zanemarivima. Rezultati pokazuju da se model razvija u skladu s postavljenim ciljevima, s prostorom za poboljšanje kod predviđanja ekstremnih vrijednosti.

Iako model pokazuje izuzetno dobre rezultate na jasno definiranim skupovima za treniranje, validaciju i testiranje, važno je dodatno potvrditi njegovu sposobnost generalizacije na različitim podskupovima podataka. Tablica 34 prikazuje evaluacijske metrike za svaki od validacijskih skupova, dok su prosječne vrijednosti izračunate radi dobivanja sveobuhvatne slike o performansama modela. Prosječne vrijednosti metrika ukazuju na visoku razinu točnosti i stabilnosti modela. SMAPE od 20,99 % upućuje na nisku prosječnu postotnu grešku u predviđanjima. RMSE od 0,0450 i MAE od 0,0349 potvrđuju malu razliku između predviđenih i stvarnih vrijednosti. MSE iznosi 0,0020, a R^2 doseže 0,9798 i ukazuje da model uspješno objašnjava gotovo 98 % varijance u podatcima. Metrike potvrđuju sposobnost modela da generalizira na različitim podskupovima bez većih oscilacija u performansama.

Tablica 34. Rezultati metrika unakrsne validacije (5 skupova modela predviđanja krivulje kumulativnog napretka)


Skup	MSE	RMSE	MAE	SMAPE	R^2
Skup 1	0,0017	0,0414	0,0337	15,65 %	0,9831
Skup 2	0,0021	0,0462	0,0338	18,28 %	0,9778
Skup 3	0,022	0,0465	0,0371	25,86 %	0,9824
Skup 4	0,0025	0,0497	0,0375	22,07 %	0,9726
Skup 5	0,0017	0,0411	0,0323	23,12 %	0,9833
Prosjek:	0,0020	0,0450	0,0349	20,99 %	0,9798

Histogram rezidualnih grešaka (slika 46) pokazuje distribuciju razlika između stvarnih i predviđenih vrijednosti. Većina reziduala koncentrirana je oko nule, što znači da su predviđanja modela uglavnom točna. Blaga asimetrija ulijevo ukazuje da model povremeno precjenjuje stvarne vrijednosti, ali greške su minimalne i zanemarive. Budući da se reziduali kreću između 0,11 i -0,11, a većina grešaka je koncentrirana između 0,05 i -0,05, većina podataka je blizu nule, a model ima visoku preciznost.



Slika 46. Histogram rezidualnih grešaka (unakrsna validacija)


Dijagram raspršenja (slika 47) pokazuje visok stupanj sličnosti između stvarnih vrijednosti i predviđenih vrijednosti. Točke su ravnomjerno raspoređene oko idealne linije, što ukazuje na precizna predviđanja modela. Nema očitih istaknutih ili sistematskih odstupanja, što sugerira da model dosljedno predviđa vrijednosti unutar cijelog raspona podataka.



Slika 47. Dijagram raspršenja stvarnih i predviđenih vrijednosti (unakrsna validacija)

Slika 48 prikazuje dijagram raspršenja reziduala, odnosno razliku između stvarnih i predviđenih vrijednosti u odnosu na predviđene vrijednosti. Reziduali su relativno ravnomjerno raspoređeni iznad i ispod idealne crvene linije, bez vidljivog sistematskog uzorka. Ovakva raspodjela sugerira da model ne pokazuje izraženu pristranost u predviđanjima. Veća raspršenost na krajevima skale predstavlja nešto slabiju

preciznost kod ekstremnih vrijednosti, dok je u srednjem rasponu vidljiva veća gustoća točaka oko nule, što potvrđuje stabilnost modela u tipičnim predviđanjima.




Slika 48. Dijagram raspršenja reziduala (unakrsna validacija)

Rezultati kutijastog dijagrama i prateći statistički pokazatelji (tablica 35 i slika 49) potvrđuju visoku preciznost modela. Srednje vrijednosti i medijani gotovo su identični, što ukazuje na ravnotežu između pozitivnih i negativnih pogrešaka. Standardne devijacije pokazuju da model pravilno replicira varijabilnost stvarnih podataka. Mjere asimetrije su vrlo slične i potvrđuju da model točno oponaša ravnotežu u distribuciji. Vrijednosti spljoštenosti su slične, a gotovo identični interkvartilni raspon potvrđuje da model prati širinu distribucije između kvartila.

Tablica 35. Statistički pokazatelji (unakrsna validacija, model predviđanja krivulje kumulativnog napretka)

Mjere	Skup za treniranje	Skup za testiranje
Srednja vrijednost greške	0,5176	0,5160
Medijan greške	0,5326	0,5256
Standardna devijacija	0,3201	0,3181
Asimetrija distribucije	-0,0941	-0,0803
Spljoštenost distribucije	-1,2644	-1,2855
Interkvartilni raspon	0,5717	0,5730



Slika 49. Kutijasti dijagram stvarnih i predviđenih vrijednosti (unakrsna validacija)

Unakrsna validacija potvrdila je stabilne i pouzdane performanse modela. Visoke vrijednosti prosječnog R^2 i niske vrijednosti RMSE i MAE pokazuju da model precizno predviđa ciljne vrijednosti i da nema značajnih pristranosti. Analiza grafova dodatno potvrđuje da model generalizira dobro na nove podatke, dok su greške ravnomjerno raspoređene i minimalne.

4.5.3. Rasprava i odabir optimalnog modela predviđanja krivulje kumulativnog napretka

Rezultati istraživanja pokazuju jasnu prednost neuronskih mreža u odnosu na tradicionalne matematičke modele u predviđanju krivulje kumulativnog napretka u građevinskim projektima. Neuronska mreža pokazala se superiornom zahvaljujući sposobnosti prepoznavanja nelinearnih odnosa i interakcija među varijablama, što matematički modeli nisu mogli adekvatno obuhvatiti. Nalazi su u skladu s ranijim istraživanjima (Chao i Chien, 2009; Wauters i Vanhoucke, 2016) koja ističu prednosti strojnog učenja u modeliranju projektnih parametara.

Rezultati kvantitativne usporedbe potvrđuju navedenu prednost (tablica 36). Najbolji rezultati matematičkih modela, postignuti kategorizacijom prema vrijednosti projekta, ostvaruju MAE od 0,056 do 0,058, RMSE od 0,073, te SMAPE od oko 26,5 %, uz koeficijent determinacije R^2 između 0,9442 i 0,9528. Neuronska mreža postiže znatno bolje rezultate. Testni skup ostvaruje MAE od 0,0291, RMSE od 0,0353, SMAPE od 17,30 %, te R^2 od 0,9877. Rezultati unakrsne validacije potvrđuju robusnost modela, s

prosječnim MAE od 0,0349, RMSE od 0,0450 i SMAPE od 20,99 %, što je i dalje bolje od najboljih rezultata matematičkih modela. Posebno je važno istaknuti da neuronska mreža dosljedno ostvaruje više vrijednosti R^2 , uz manje oscilacije među skupovima, što ukazuje na veću stabilnost i sposobnost generalizacije.

Tablica 36. Usporedba performansi najboljih matematičkih modela i modela neuronske mreže u predviđanju krivulje kumulativnog napretka

Model	Podskup	MAE	MSE	SMAPE	RMSE	R^2
Matematički model	< 10 milijuna eura	0,0580	0,0050	26,78 %	0,0730	0,9528
	> 10 milijuna eura	0,0560	0,0050	26,50 %	0,0730	0,9442
Neuronska mreža	Testni skup	0,0291	0,0012	17,30 %	0,0353	0,9877
	Unakrsna validacija	0,0349	0,0020	20,99 %	0,0450	0,9798

Iako neuronska mreža nije trenirana na cijeloj dostupnoj bazi, već na 80 % podataka, uspjeva postići bolje rezultate od matematičkih modela koji koriste čitav skup. Rezultat potvrđuje da dobro pripremljeni i normalizirani podatci omogućuju neuronskoj mreži učinkovito prepoznavanje obrazaca i generiranje točnih predviđanja bez potrebe za ručnim razvrstavanjem ili dodatnim proširivanjem skupa. Prednost neuronske mreže ogleda se upravo u sposobnosti da uči iz postojećih informacija i generalizira na nove primjere, što dodatno potvrđuju stabilne metrike i rezultati unakrsne validacije. Vizualizacije rezultata neuronske mreže pokazuju konzistentne i puno uspješnije rezultate od matematičkih modela. Ovo ukazuje da je model neuronske mreže pouzdan, a podatci dovoljno konzistentni da podrže preciznost.

Unatoč tome, tradicionalni matematički modeli, kao što su beta distribucija (Bhaumik, 2016; Kim i Reinschmidt, 2009), polinomske funkcije (Ostojić-Škomrlj i Radujković, 2012), Weibullova distribucija (Nassar i dr., 2005), Rayleighova distribucija (Obi i dr., 2024) i Gompertzova funkcija (Nannini i dr., 2017) pokazali su dobru razinu preciznosti u predviđanju krivulje kumulativnog napretka. Njihova prednost leži u jednostavnosti primjene, transparentnosti i interpretabilnosti rezultata zbog čega su prikladni u analitički jednostavnijim kontekstima ili kada je količina dostupnih podataka ograničena. Takvi modeli omogućuju brzo razumijevanje i lako objašnjavanje rezultata. Međutim, njihova primjena zahtijeva prethodnu kategorizaciju projekata (Kaka i Price, 1993), a time smanjuje fleksibilnost i povećava rizik od pogrešaka u složenijim uvjetima.

Neuronska mreža ne zahtijeva prethodnu ručnu kategorizaciju podataka, već se automatski prilagođava svim dostupnim informacijama i samostalno prepoznaje ključne obrasce, štedi vrijeme i smanjuje mogućnost pogreške, uz zadržavanje visoke razine točnosti predviđanja. Primjena neuronskih mreža posebno je učinkovita u

građevinskim projektima koji su obilježeni kompleksnošću, nelinearnim odnosima i velikim brojem varijabli. Na taj način neuronske mreže smanjuju mogućnost pogreške uzrokovane ljudskom prosudbom i omogućuju veću točnost i robusnost predviđanja.

Ograničenja neuronske mreže uočena su u predviđanju ekstremnih vrijednosti na početku i kraju krivulje. Iako ti segmenti nemaju presudan utjecaj na ukupnu pouzdanost modela, budući da su te krajnje vrijednosti unaprijed poznate (početna vrijednost iznosi 0, a završna 1), moguće je u budućnosti primijeniti dodatne tehnike za poboljšanje preciznosti u tim fazama. Slične izazove uočili su i Wauters i Vanhoucke (2016) te Erzaij i dr. (2021).

Rezultati pokazuju da neuronske mreže nadmašuju tradicionalne matematičke modele u preciznosti predviđanja kumulativnog napretka, čime se potvrđuje pomoćna hipoteza H3. Neuronska mreža se ističe mogućnošću automatskog prepoznavanja i integracije obrazaca iz različitih kategorija te nadmašuje matematičke pristupe koji zahtijevaju ručnu kategorizaciju podataka. Rezultati ukazuju na snažan potencijal primjene neuronskih mreža u realnim projektima, osobito u kontekstu dinamičnog i nestrukturiranog građevinskog okruženja gdje je teško unaprijed definirati sve uvjete modeliranja. Iako inicijalna implementacija modela zahtijeva vrijeme i tehničku stručnost, jednom uspostavljen model omogućuje jednostavne nadogradnje i prilagodbe, što ga čini dugoročno održivim rješenjem za predviđanje krivulje kumulativnog napretka u građevinskim projektima.

5. PERSPEKTIVNI DIO

Ovo poglavlje prikazuje perspektivne aspekte primjene razvijenih modela predviđanja, s naglaskom na potvrdu njihove funkcionalnosti na aktivnom građevinskom projektu i identifikaciju tržišta građevinske industrije koja dijele slične gospodarske uvjete i dinamiku s Hrvatskom. Time se osigurava šira relevantnost istraživanja i otvaraju mogućnosti za buduće prilagodbe i širu regionalnu primjenu.

5.1. Primjena razvijenih modela na aktivnom građevinskom projektu

Iako su ključne značajke za predviđanje prekoračenja ugovorenog trajanja i iznosa identificirane tijekom razvoja modela, njihova važnost dolazi do posebnog izražaja u fazi primjene na konkretnom građevinskom projektu u fazi izvođenja. U toj fazi modeli se primjenjuju kao podsustav za upravljanje modelima. Ovaj podsustav omogućuje unos podataka, izvođenje simulacija, „što-ako“ analiza i generiranje predviđanja u stvarnim uvjetima izvođenja radova. Fokus se tako premješta s tehničke evaluacije na operativnu interpretaciju rezultata, s ciljem aktivne podrške donošenju odluka tijekom izvedbe. Najutjecajnije značajke prepoznaju se i koriste kao osnova za proaktivno upravljanje. Tablica 37 prikazuje paralelno rangiranje značajki prema važnosti za oba modela predviđanja te omogućuje jasnije razumijevanje na koje kriterije uspješnosti treba usmjeriti pažnju u praktičnoj primjeni.

Tablica 37. Najvažnije značajke modela predviđanja prekoračenja ugovorenog trajanja i ugovorenog iznosa

Rang	Model predviđanja prekoračenja ugovorenog trajanja	Model predviđanja prekoračenja ugovorenog iznosa
1	Analiza dinamičkog plana	Analiza dinamičkog plana
2	Upravljanje sukobima	Vrsta ugovora: ugovor o gradnji
3	Ugovorena vrijednost radova	Ugovorena vrijednost radova
4	Tip: cestovna infrastruktura	Trend promjena i dodatnih radova
5	Trend promjena i dodatnih radova	Tip: visokogradnja
6	Zadovoljstvo investitora stručnošću izvođača	Kvaliteta projektne dokumentacije
7	Pridržavanje rokova aktivnosti	Zadovoljstvo sudionika
8	Upravljanje promjenama	
9	Zadovoljstvo sudionika	
10	Kvaliteta projektne dokumentacije	

Značajke koje su identificirane kao ključne za oba modela (analiza dinamičkog plana, ugovorena vrijednost radova, kvaliteta projektne dokumentacije, zadovoljstvo sudionika i trend dodatnih radova) upućuju na mogućnost istodobnog utjecaja na prekoračenja ugovorenog trajanja i iznosa. To znači da se u praksi odluke trebaju donositi koordinirano jer iste značajke istodobno utječu na više ciljanih ishoda projekta. Specifične značajke unutar svakog modela omogućuju preciznije usmjeravanje mjera prilagodbe.

Značajke se u ovoj fazi dijele na nepromjenjive i promjenjive. Nepromjenjive značajke obuhvaćaju elemente poput ugovorene vrijednosti radova, tipa projekta te vrste ugovora. Riječ je o parametrima koji se definiraju u fazi planiranja i ugovaranja, a kao takvi nisu podložni naknadnim izmjenama u fazi izvođenja. S druge strane, promjenjive značajke uključuju analizu dinamičkog plana, upravljanje sukobima, trend promjena i dodatnih radova, zadovoljstvo investitora stručnošću izvođača, pridržavanje rokova aktivnosti, upravljanje promjenama, zadovoljstvo sudionika i kvalitetu projektne dokumentacije. Upravo su te varijable podložne aktivnom upravljanju tijekom izvođenja građevinskog projekta, čime predstavljaju konkretan prostor za optimizaciju izvedbe.


Za primjenu razvijenog modela koriste se podatci s aktivnog gradilišta. Analiza se provodi nakon prve trećine planiranog trajanja projekta. Svi ulazni podatci (tablica 38) pripremaju se i obrađuju u skladu s tablicama 13 i 14 opisanim u metodološkom dijelu.

Tablica 38. Ulazni podatci o aktualnom projektu

Naziv kriterija	Ulazni podatak
Tip projekta	Komunalna infrastruktura
Vrsta ugovora	Fidic
Faza projekta	Prva trećina
Ugovorena vrijednost radova	23000000
Kvaliteta projektne dokumentacije	0,0212
Upravljanje promjenama	2
Analiza dinamičkog plana	-0,4094
Pridržavanje rokova aktivnosti	3
Omjer troškova	0,1160
Trend promjena i dodatnih radova	0,0129
Identifikacija opasnosti	2
Stopa nezgoda	0,2
Fluktuacija zaposlenika	3
Upravljanje sukobima	5

Zadovoljstvo sudionika	3
Zadovoljstvo investitora stručnošću izvođača	5

Modeli predviđaju da bi projekt, u postojećim uvjetima, mogao premašiti planirano trajanje za 26,40 %, dok se s financijske strane ne očekuje prekoračenje, već preostaje sigurnosna rezerva od 3,34 %. Temeljem rezultata, izrađuje se krivulja kumulativnog napretka prikazana na slici 50. Krivulja vizualizira očekivani financijski tijek izvedbe projekta uzimajući u obzir procijenjeno prekoračenje trajanja i iznosa, kao i ostale ulazne parametre u skladu s procesom iz potpoglavlja 3.3.2. Omogućuje dionicima uvid u trenutak i intenzitet odstupanja, pružajući kontekst koji olakšava donošenje odluka.



Slika 50. Krivulja kumulativnog napretka aktivnog građevinskog projekta

Na početku i kraju krivulje kumulativnog napretka uočavaju se manja odstupanja, što je već komentirano u potpoglavlju 4.5.2. Ipak, ta odstupanja nisu presudna jer se analiza provodi nakon prve trećine trajanja projekta, gdje je točnost predviđanja krivulje potvrđena, a početne vrijednosti više ne utječu na odlučivanje.

U praktičnoj primjeni, krivulja se iz normaliziranih vrijednosti pretvara u stvarne veličine, pri čemu se iznosi prikazuju u eurima, a trajanje u mjesecima. Dobivene vrijednosti zatim se uspoređuju s trenutnim stanjem izvedenih i naplaćenih radova, čime se dodatno povećava korisnost krivulje kao alata za praćenje. Zbog povjerljivosti podataka, ova usporedba nije uključena u disertaciju. Unatoč tome, prikaz krivulje pridonosi boljem razumijevanju analitičkih nalaza i olakšava komunikaciju među dionicima, osobito u kontekstu budućih simulacija i donošenja odluka.

Nakon pregleda rezultata predviđanja prekoračenja i krivulje kumulativnog napretka, dionici donose odluku da je predviđeno prekoračenje ugovorenog trajanja neprihvatljivo. U skladu s tim, provodi se simulacija s ciljem identifikacije kombinacija značajki koje omogućuju ostvarenje ciljanih ishoda bez narušavanja značajki koje već smanjuju rizik od prekoračenja. Ograničenja značajki definirana su prema operativnim mogućnostima projekta i prikazana u tablici 39.

Tablica 39. Ograničenja značajki aktivnog građevinskog projekta

Značajke	Raspon vrijednosti
Analiza dinamičkog plana	-0,40 - 0,20; 0,1
Upravljanje sukobima	5
Ugovorena vrijednost radova	23000000
Tip: cestovna infrastruktura	0
Trend promjena i dodatnih radova	0,05 - 0,30; 0,05
Zadovoljstvo investitora stručnošću izvođača	5
Pridržavanje rokova aktivnosti	3, 4, 5
Upravljanje promjenama	2, 3, 4,5
Zadovoljstvo sudionika	3, 4, 5
Kvaliteta projektne dokumentacije	0,05 - 0,30; 0,05

Na temelju definiranih ograničenja, generira se 9.072 mogućih kombinacija značajki koje se unose u model predviđanja prekoračenja trajanja. Izlazni skup podataka filtrira se tako da obuhvati samo one kombinacije koje rezultiraju predviđanjem od 0 % prekoračenja. Filtriranje rezultira sa četiri prihvatljive kombinacije značajki (tablica 40) koje se dalje analiziraju kao realni scenariji za donošenje odluka.

Tablica 40. Kombinacije značajki koje daju predviđanje prekoračenja ugovorenog trajanja 0 %

Kombinacija	Analiza dinamičkog plana	Upravljanje sukobima	Trend promjena i dodatnih radova	Zadovoljstvo investitora stručnošću izvođača	Pridržavanje rokova aktivnosti	Upravljanje promjenama	Zadovoljstvo sudionika	Kvaliteta projektne dokumentacije
1	0,00	5	0,05	5	5	4	5	0,25
2	0,00	5	0,05	5	5	3	5	0,30
3	0,00	5	0,05	5	5	5	4	0,30
4	0,10	5	0,05	5	5	5	5	0,35

Analiza jasno pokazuje da za postizanje cilja od 0 % prekoračenja ugovorenog trajanja projekta postoji skup specifičnih uvjeta koji se moraju istovremeno ispuniti. U svim varijantama, zadržana je maksimalna ocjena za upravljanje sukobima i zadovoljstvo investitora stručnošću izvođača. Također, sve varijante uključuju najvišu ocjenu za pridržavanje rokova aktivnosti, što još jednom potvrđuje da dosljedno provođenje planiranih koraka ima snažan utjecaj na uspjeh u pogledu poštivanja vremenskih rokova. Ostale značajke pokazuju određenu razinu fleksibilnosti. Upravljanje promjenama varira između 3 i 5, dok zadovoljstvo sudionika ostaje unutar raspona od 4 do 5. To implicira da model tolerira manju razinu nesuglasica i umjereno razvijen sustav upravljanja promjenama, pod uvjetom da su ključni mehanizmi stabilni. Značajka kvalitete projektne dokumentacije prisutna je u vrijednostima između 0,25 i 0,35, što potvrđuje da je određena razina dodatnih, vantroškovničkih i nepredviđenih radova očekivana i prihvatljiva, ali samo unutar strogo kontroliranih granica. Nalaz dodatno naglašava važnost tehničke pripreme i dokumentacijske preciznosti kao uvjeta za uspješno vođenje građevinskih projekata. Trend promjena i dodatnih radova pokazuje minimalnu dopuštenu razinu od 0,05 i ukazuje da model ne tolerira značajnije promjene u obuhvatu. Stabilnost projektnih zahtjeva izdvaja se kao jedan od najvažnijih preduvjeta za poštivanje roka. Vrijednosti značajke analiza dinamičkog plana u prihvatljivim kombinacijama kreću se između 0,00 i 0,10, što znači da se nastavak projekta mora odvijati u skladu s planom ili ubrzanim tempom. S obzirom na dosadašnje kašnjenje od preko 40 %, model ne tolerira dodatna odstupanja te jasno ukazuje na potrebu za poticanjem ubrzanja.

Za daljnje usmjeravanje projekta odabire se kombinacija 2 jer u najvećoj mjeri odgovara realnim operativnim mogućnostima. Iako se kombinacija 3 razlikuje samo u upravljanju promjenama i zadovoljstvu sudionika, procijenjuje se da je na ovom konkretnom projektu jednostavnije i realnije povećati zadovoljstvo sudionika nego postići maksimalnu razinu upravljanja promjenama. Na temelju odabrane kombinacije definiraju se konkretne mjere prilagodbe koje omogućuju usklađivanje stvarnih uvjeta s ciljanom vrijednošću značajki.

Značajke upravljanje sukobima i zadovoljstvo investitora stručnošću izvođača već su usklađene s ciljnim vrijednostima.

Prema kombinaciji 2, pridržavanje rokova aktivnosti i zadovoljstvo sudionika potrebno je povećati s trenutačne razine 3 na 5. Povećanje vrijednosti značajke pridržavanje rokova aktivnosti zahtijeva usklađen angažman svih ključnih dionika i pravovremenu dostavu potrebne dokumentacije i informacija usklađenih s ugovornim obavezama. Nadzorni inženjer koordinira protok dokumentacije, prati izvršenje obveza i kontrolira poštivanje rokova. Na tjednoj koordinaciji sudionike upozorava na nadolazeće rokove i obavještava o eventualnim prekoračenjima. U slučaju da pojedini timovi, bilo izvođača, investitora ili nadzora, ne mogu ispuniti planirane aktivnosti u predviđenim rokovima,

svaki je dužan osigurati dodatne resurse kako bi se obveze izvršavale pravodobno i bez zastoja.

Povećanje zadovoljstva sudionika moguće je postići jačanjem komunikacije, jasnijom podjelom odgovornosti i boljom suradnjom među svim dionicima (Aziz i dr., 2022; Borcharding, 1978; Hamzah i dr., 2024). Svaki predstavnik tima za svoj tim razrađuje jasnu podjelu odgovornosti, s uputama tko za što odgovara i kome podnosi izvještaje. Podjela se prezentira na tjednoj koordinaciji kako bi svi sudionici znali tko je zadužen za koju aktivnost, s kim komunicira i kako se informacije razmjenjuju. Na taj se način smanjuju gubici vremena u prenošenju informacija, uz očuvanje strukture i hijerarhije u svakom timu. Uz formalnu komunikaciju, preporučuje se poticanje i neformalnih oblika komunikacije koji mogu pozitivno utjecati na radnu atmosferu. Važno je da se ovu mjeru primjenjuje ne samo između timova izvođača, investitora i nadzora, nego i unutar svakog pojedinog tima.

Vrijednost upravljanja promjenama trenutačno je na razini 2, odnosno sustav još nije razvijen te se službeno evidentira samo dio izmjena. Ciljana vrijednost je 3. Stoga se kao mjera prilagodbe postavlja da nadzorni inženjer, u suradnji s izvođačem, razradi detaljan sustav za praćenje i odobravanje promjena. Investitor potvrđuje konačnu verziju sustava i osigurava njegovu provedbu. Sustav se usuglašava i primjenjuje unutar 15 dana od donošenja odluke na tjednoj koordinaciji.

Vrijednost kvalitete projektne dokumentacije potrebno je povećati s 0,0212 na ciljanih 0,30. Glavna inicijativa za ovu značajku je na investitoru, koji treba angažirati projektanta za detaljnu reviziju i usklađivanje dokumentacije. Revidirani projekt mora se dostavljati u skladu s dinamičkim planom, pri čemu se izmjene moraju biti dostupne najmanje mjesec dana prije izvođenja aktivnosti na koju se izmjena odnosi, kako bi se osiguralo dovoljno vremena za pripremu, nabavu materijala i organizaciju radova. Nadzorni inženjer evidentira sve zaprimljene izmjene i potvrđuje njihovu potpunost. Izvođač je dužan pravodobno dostaviti sve komentare i prijedloge, a o statusu ažuriranja dokumentacije redovito se izvještavaju svi sudionici na tjednim koordinacijama. Na taj način osigurava se da svi raspolažu važećom dokumentacijom, čime se smanjuje rizik od zastoja i nepredviđenih izmjena tijekom izvođenja.

U skladu s ciljanom kombinacijom, očekuje se povećanje vrijednosti trenda promjena i dodatnih radova s 0,0129 na 0,05. Izvođač je dužan, u skladu s revidiranom dokumentacijom, dokumentirati, obračunati i tražiti priznanje svih dodatnih, nepredviđenih i vantroškovničkih radova. Nadzorni inženjer provjerava opravdanost i opseg potraživanja, dok investitor odobrava potraživanja i zadužen je za pripremu aneksa ugovora. Potraživanja se dostavljaju prema usuglašenom sustavu upravljanja promjenama i u skladu s ugovornim odredbama.

Vrijednost analize dinamičkog plana potrebno je podići s trenutačne negativne vrijednosti -0,4094 na 0,00 kako bi se eliminiralo kašnjenje i uskladio tempo radova s

planom. Izvođač je odgovoran za organizaciju dodatnih resursa i intenzivniju koordinaciju na gradilištu, a o poduzetim radnjama dužan je redovito izvještavati na tjednim koordinacijama. Nadzorni inženjer prati realizaciju i izvještava investitora.

Na temelju odabrane kombinacije 2 ažurira se i krivulja kumulativnog napretka, koja sada odražava planirane mjere prilagodbe i služi sudionicima kao novi referentni scenarij za praćenje napretka projekta u stvarnom vremenu. U slučaju odstupanja, sudionici mogu ponoviti postupak i prilagoditi planirane mjere.

Zaključno, faza primjene modela i adaptivni ciklus potvrđuju da model pouzdano identificira obrasce koji vode prema pravovremenom završetku projekta. Na temelju provedenih simulacija, može se zaključiti da je šesti pomoćni cilj istraživanja u potpunosti ostvaren. Primjenom razvijenog modela na aktivnom građevinskom projektu omogućena je analiza predviđenih ishoda, evaluacija utjecaja pojedinih značajki na rezultate te identifikacija kombinacija i raspona vrijednosti koje vode prema ostvarivanju željenog ishoda. Time se potvrđuje i postavljena hipoteza H4, prema kojoj simulacije na temelju razvijenih modela predviđanja omogućuju identifikaciju intervala vrijednosti značajki koje vode prema postizanju željenih projektnih ishoda. U kontekstu kompleksnosti građevinskih projekata, nalazi predstavljaju čvrstu osnovu za donošenje odluka i usmjeravanje projektnih timova prema učinkovitijem upravljanju vremenom. Model se pokazao primjenjivim ne samo kao analitički alat, već i kao konkretna podrška u upravljanju građevinskim projektom u stvarnim uvjetima.

5.2. Identifikacija sličnih tržišta građevinske industrije

Potpoglavlje identificira zemlje koje dijele slične gospodarske uvjete i dinamiku građevinske aktivnosti s Hrvatskom, s ciljem procjene šire primjenjivosti rezultata istraživanja. Analiza se temelji na ključnim pokazateljima građevinske aktivnosti prema podacima Eurostata. Odabrano razdoblje od 2013. do listopada 2024. omogućuje praćenje trendova od ulaska Hrvatske u Europsku uniju, čime se osigurava konzistentan i relevantan kontekst za usporedbu.

Koriste se sljedeći pokazatelji:

- (1) Indeks građevinske proizvodnje odabire se kao primarni pokazatelj jer najizravnije odražava promjene u obujmu građevinskih radova.
- (2) Indeks broja zaposlenih ukazuje na promjene u zaposlenosti u građevinskom sektoru, što često reflektira povećanje ili smanjenje građevinske aktivnosti.
- (3) Indeks broja odrađenih sati daje uvid u intenzitet rada u sektoru i može poslužiti kao indikator produktivnosti i radne angažiranosti.

(4) Indeks bruto plaća odražava ekonomske uvjete u građevinskom sektoru, uključujući pritiske na plaće i financijsko stanje tržišta rada.

Zajedno, ovi pokazatelji nude sveobuhvatan prikaz dinamike sektora, ne samo kroz promjene u volumenu proizvodnje, već i kroz povezane promjene na tržištu rada i u gospodarskoj okolini (Eurostat, pristupano 1.10.2024.). Podatci se normaliziraju, a zemlje s nepotpunim nizovima isključuju kako bi se osigurala valjanost analize.

Za grupiranje zemalja koristi se Elbow metoda kojom se određuje optimalan broj klastera na temelju ukupne varijacije unutar klastera. „Lakat“ u krivulji služi kao vizualni pokazatelj optimalnog broja klastera. Tablica 41 daje pregled zemalja koje se najmanje tri puta svrstavaju u isti klaster s Hrvatskom.

Tablica 41. Pojavljivanja zemalja u klasteru s Hrvatskom

Zemlja	Broj pojavljivanja
Danska	4
Italija	4
Cipar	4
Estonija	3
Mađarska	3
Nizozemska	3
Austrija	3
Rumunjska	3
Slovenija	3
Švedska	3
Norveška	3
Srbija	3

Za dodatnu potvrdu sličnosti provodi se i analiza Pearsonove korelacije između Hrvatske i ostalih zemalja, zasebno za svaki od četiri pokazatelja. Pearsonova korelacija mjeri koliko su kretanja u dvjema zemljama paralelna tijekom vremena i omogućuje uvid u stupanj sličnosti trendova. Ograničenje metode je njena osjetljivost na linearne odnose. Međutim, postavljaju se pragovi koji osiguravaju relevantnost. U obzir se uzimaju zemlje s korelacijom iznad 0,8 u najmanje tri indikatora, pri čemu četvrti nije manji od 0,7. Rezultati su prikazani u tablici 42.


Kombiniranjem rezultata klaster analize i Pearsonove korelacije identificiraju se zemlje koje u oba pristupa dosljedno pokazuju sličnost s Hrvatskom. Te zemlje su Rumunjska, Danska, Slovenija, Mađarska, Norveška, Srbija, Nizozemska, Italija, Austrija i Cipar.

Sličnosti se može objasniti geografskom i gospodarskom blizinom, ali i sličnim razvojnim fazama, dostupnošću europskih fondova, strukturnim značajkama građevinske industrije te zajedničkim regulatornim okvirom.

Tablica 42. Zemlje s visokom korelacijom s Hrvatskom

Indeksi	Indeks proizvodnje	Bruto plaće	Odrađeni sati	Broj zaposlenih
Rumunjska	0,9228	0,9558	0,9382	0,9601
Danska	0,9160	0,8866	0,9288	0,9295
Slovenija	0,9058	0,9757	0,6155	0,9908
Mađarska	0,8209	0,9522	0,8971	0,9412
Norveška	0,8217	0,9186	0,8994	0,9070
Srbija	0,8923	0,9689	0,7542	0,9855
Nizozemska	0,8500	0,9580	0,7267	0,9822
Italija	0,8937	0,9249	0,7579	0,8308
Austrija	0,8742	0,9427	0,8161	0,7382
Cipar	0,7647	0,8701	0,8917	0,9220

Rezultati su važni jer upućuju na potencijalnu primjenjivost razvijenih modela i analitičkog pristupa u širem europskom kontekstu, osobito u zemljama s visokom korelacijom i sličnim institucionalnim uvjetima. Vizualna karta (slika 51) potvrđuje da je većina zemalja geografski povezano, što dodatno pojačava argument za njihovo uključivanje u komparativne analize i moguća buduća proširenja istraživanja.



Slika 51. Zemlje sličnih gospodarskih trendova u građevinskoj industriji

6. ZAKLJUČAK

U suvremenom kontekstu, u kojem građevinska industrija predstavlja značajan dio gospodarstva, uspjeh projekata i njihovo završavanje u okviru ugovorenog trajanja i iznosa predstavlja složen izazov. Unatoč ubrzanom razvoju metodologija upravljanja projektima i primjeni naprednih informacijskih tehnologija, velik broj projekata i dalje bilježi značajna odstupanja od početno planiranih ili ugovorenih vrijednosti. Odstupanja nisu samo gospodarski problem nego i društveni jer dovode do kašnjenja u isporuci infrastrukturnih i drugih javnih dobara te povećavaju rizike poput pravnih sporova i reputacijskih šteta za uključene dionike.

Iako se u praksi i dalje često primjenjuje tradicionalni koncept „željeznog trokuta“ (vrijeme, trošak, kvaliteta), recentna istraživanja pokazala su da taj pristup nije dovoljan za potpuno razumijevanje uspješnosti projekta. Temeljna motivacija ovog istraživanja proizašla je upravo iz potrebe za dubljim razumijevanjem uzroka odstupanja i za unaprjeđenjem sposobnosti pravovremenog prepoznavanja rizika u fazi izvođenja radova. Posebna važnost pridala se uključivanju perspektive različitih dionika, među kojima često dolazi do nesklada u percepciji što se smatra uspjehom, a što neuspjehom građevinskog projekta. Neusklađeni interesi i nedostatna komunikacija dodatno pojačavaju složenost upravljanja građevinskim projektom i potvrđuje potrebu za sveobuhvatnijim pristupima.

U okviru disertacije razvijen je teorijski utemeljen i empirijski potvrđen model za predviđanje performansi i konačnih ishoda građevinskih projekata. Polazište modela bilo je detaljnije razumijevanje uzroka odstupanja od ugovorenog trajanja i iznosa upravo u fazi izvođenja radova, kada su takva odstupanja najčešća i imaju najveći utjecaj na uspjeh projekta. Model se temelji na primjeni metoda strojnog učenja te objedinjuje podatke prikupljene iz stvarnih projekata te uvid ključnih dionika uključenih u proces izvođenja. Poseban naglasak stavljen je na međusobno povezivanje područja performansi, koja su identificirana kao ključna za postizanje uspjeha projekta, u jedinstven okvir predviđanja.

U tom kontekstu, istraživanjem su ostvareni ciljevi postavljeni na početku rada, i to kroz jasno strukturiranu metodologiju i detaljnu analizu. Prvi pomoćni cilj odnosio se na razvoj teorijskog okvira za predviđanje performansi građevinskih projekata. Razvijeni okvir u obzir je uzeo suvremene standarde i metodologije upravljanja građevinskim projektima, teoriju upravljanja dionicima, višedioničku perspektivu, zajedničko razumijevanje ciljeva te usklađen pristup evaluaciji uspješnosti. U teorijskom okviru su identificirana ključna područja performansi, a naglašena je i važnost sustava za podršku odlučivanju u unaprjeđenju procesa upravljanja. Okvir je uključio primjenu umjetne inteligencije i metoda strojnog učenja te analizu krivulje kumulativnog napretka. Integracija svih analiziranih teorijskih pristupa poslužila je kao

čvrsta osnova za razvoj modela predviđanja performansi i ishoda građevinskih projekata.

U skladu s drugim pomoćnim ciljem, razvijen je evaluacijski okvir i definiran postupak koji se može primjenjivati u okruženju s više dionika za identifikaciju i rangiranje područja performansi ključnih za postizanje uspjeha građevinskih projekata. Takav okvir osigurao je objektivan pristup, poticanje suradnje dionika i donošenje informiranih odluka koje uvažavaju različite interese.

Nadovezujući se na taj korak, uspostavljena je jasna veza između mjerenja i predviđanja performansi i ishoda građevinskih projekata. Identificirano je sedam ključnih područja performansi (kvaliteta, vrijeme, trošak, sigurnost, produktivnost, zadovoljstvo sudionika i zadovoljstvo investitora). Evaluacijski okvir omogućio je dublji uvid u međusobne odnose između područja performansi i stvarnih projektnih ishoda, čime je ostvaren treći pomoćni cilj. Razvoj i validacija modela kroz višestruku studiju slučaja potvrdili su njegovu praktičnu primjenjivost u realnim uvjetima te omogućili prepoznavanje područja performansi s najvećim utjecajem na uspješnost projekta.

U okviru četvrtog pomoćnog cilja razvijeni su i validirani modeli predviđanja prekoračenja ugovorenog trajanja i iznosa građevinskih projekata primjenom metoda strojnog učenja, s posebnim fokusom na neuronske mreže. Posebna pažnja posvećena je identifikaciji značajki koje najviše utječu na točnost predviđanja te optimizaciji arhitekture i prilagodbi hiperparametara, čime je dodatno poboljšana točnost predviđanja modela. Modeli su razvijeni na temelju podataka prikupljenih iz realiziranih građevinskih projekata, a njihova primjenjivost potvrđena je unakrsnom validacijom. Postignute metrike, uključujući visoke vrijednosti koeficijenta determinacije i niske pogreške, potvrdile su robusnost i pouzdanost razvijenih modela. Analiza važnosti značajki pokazala je da uz tehničke čimbenike na projektne ishode snažno utječu i financijski, organizacijski i interpersonalni čimbenici, što je dodatno potvrdilo potrebu za holističkim pristupom u modeliranju predviđanja ishoda.

U sklopu petog pomoćnog cilja razvijen je i validiran model za predviđanje kumulativnog napretka građevinskog projekta temeljen na metodama strojnog učenja. Usporedba performansi razvijenog modela s tradicionalnim matematičkim pristupima pokazala je da neuronske mreže daju točnija predviđanja, uz dodatnu prednost što ne zahtijevaju ručnu kategorizaciju podataka. Takva sposobnost automatskog prepoznavanja obrazaca i odnosa među varijablama dodatno je potvrdila njegovu praktičnu primjenjivost u stvarnim uvjetima provedbe projekta.

Šesti pomoćni cilj odnosio se na ocjenu uspješnosti razvijenih modela primjenom na konkretnom građevinskom projektu u tijeku. U tu svrhu provedena je analiza predviđenih ishoda i simulacija odlučivanja kojom su ispitani učinci promjena pojedinih značajki na konačne ishode. Simulacijski scenariji omogućili su identifikaciju kombinacija značajki koje dovode do ciljanih ishoda. Time je potvrđena točnost

razvijenih modela i njihova korisnost u stvarnom kontekstu upravljanja građevinskim projektima. Kao takav, model postaje vrijedan alat u rukama izvođača, pružajući podršku za proaktivno upravljanje resursima, rokovima i suradnjom među dionicima.

Na temelju provedenih analiza potvrđena je središnja hipoteza istraživanja, prema kojoj je primjenom teorije upravljanja dionicima i metoda strojnog učenja moguće razviti kvantitativne modele predviđanja performansi i ishoda građevinskih projekata koji omogućuju pravovremenu procjenu rizika i podršku u donošenju odluka, uz primjenjivost na projekte financirane javnim sredstvima s ugovornim vrijednostima između 7,5 i 25 milijuna eura. Kvalitativni i kvantitativni elementi istraživanja međusobno su se nadopunjavali i zajedno pridonijeli potvrdi svih pomoćnih hipoteza. Dokazana je važnost identifikacije ključnih područja performansi, optimizacije modela odabirom relevantnih značajki i prilagodbom arhitekture i hiperparametara. Također je potvrđena prednost neuronskih mreža u odnosu na klasične matematičke modele za predviđanje krivulje kumulativnog napretka te je omogućena identifikacija intervala vrijednosti koji vode prema postizanju željenih projektnih ishoda.

Na temelju svega navedenog, ključni znanstveni doprinos disertacije očituje se u razvoju i validaciji sveobuhvatnog modela koji integrira teorijske i empirijske uvide, suvremene metode strojnog učenja i višedioničku perspektivu, čime se unapređuje praksa upravljanja građevinskim projektima u složenim i promjenjivim uvjetima izvođenja.

6.1. Znanstveni doprinos istraživanja

Znanstveni doprinos ovog istraživanja ostvaren je kroz teorijski, metodološki i empirijski napredak u području predviđanja performansi i ishoda građevinskih projekata.

Razvijen je teorijski okvir koji povezuje ključna područja performansi s višedioničkom perspektivom i teorijom upravljanja dionicima. Povezivanjem tehničkih, organizacijskih i interpersonalnih čimbenika u jedinstvenu cjelinu unaprijeđeno je razumijevanje međuodnosa „tvrdih“ i „mekih“ čimbenika koji oblikuju ishode građevinskih projekata.

Na temelju teorijskog modela razvijen je evaluacijski okvir, koji ga operacionalizira kroz hijerarhijsku strukturu ciljeva, čime se stvara sustav za objektivno praćenje i predviđanje ishoda. Ovaj okvir spojio je kvalitativne i kvantitativne pristupe, povezao rezultate sustavnog pregleda literature s polustrukturiranim intervjuima i analizom projektnih podataka. Primijenjene su metode poput MacDonaldove jednadžbe za usporedbu ugovorenih i stvarnih parametara, Likertove ljestvice za mjerenje percepcija dionika i vizualna kategorizacija za prikaz odstupanja, čime je omogućeno dublje razumijevanje kako mjerljivih pokazatelja, tako i percepcija ključnih dionika. Primjenom

višestruke studije slučaja potvrđena je primjenjivost i prilagodljivost ovog okvira u različitim kontekstima, čime je osigurana veza između teorije i prakse.

Ključni znanstveni doprinos čini razvoj i validacija modela predviđanja prekoračenja ugovorenog trajanja i iznosa. Modeli kombiniraju tehničke podatke s kvantificiranim „mekim“ čimbenicima. Temelje se na ukupno 16 značajki (3 kategorijske i 13 numeričkih) pri čemu su sve značajke precizno kvantificirane kroz jasno definirane kriterije i standardizirane skale. Kategorijske značajke kodirane su tehnikom One-Hot Encoding, dok su numeričke značajke standardizirane kako bi se osigurala međusobna usporedivost podataka. Kvalitativne informacije prikupljene su polustrukturiranim intervjuima i kvantificirane Likertovim ljestvicama. Na taj je način osigurana konzistentnost i objektivnost pretvaranja subjektivnih ocjena u numeričke varijable. Dodatnu vrijednost doprinosi primjena metode SMOGN za balansiranje neuravnoteženih podataka, koja poboljšava pouzdanost predviđanja, te uporaba algoritma slučajne šume za identifikaciju najrelevantnijih značajki. Na taj je način postignuta visoka točnost uz minimalni broj ulaznih podataka, što je ključno za praktičnu primjenu, pri čemu su za predviđanje prekoračenja ugovorenog trajanja i iznosa postignute niske vrijednosti metrika pogreške ($MSE = 0,0029/0,0011$; $RMSE = 0,0536/0,0336$; $MAE = 0,0435/0,0255$; $R^2 = 0,9497/0,9081$).

Važan doprinos čini i sustavna usporedba tradicionalnih matematičkih modela za predviđanje krivulje kumulativnog napretka s modelom razvijenim primjenom neuronske mreže. Razvijen je sustav kategorizacije podataka prema tipu i vrijednosti projekta, što je omogućilo bolje prilagođavanje modela specifičnostima pojedinih skupina i povećalo točnost predviđanja matematičkih modela. Uvedena je normalizacija i standardizacija značajki radi osiguravanja usporedivosti podataka. Usporedbom metrika potvrđeno je da neuronska mreža ostvaruje superiorne rezultate ($MAE = 0,0291$; $MSE = 0,0012$; $RMSE = 0,0353$; $R^2 = 0,9877$) u odnosu na matematičke modele, čime se potvrđuje potencijal naprednih metoda strojnog učenja za predviđanje krivulje kumulativnog napretka građevinskih projekata.

Važan doprinos čini i razvoj originalnog koda za implementaciju modela predviđanja u okruženju Jupyter Notebook, čime je osigurana primjenjivost i reproducibilnost istraživanja.

Znanstveni doprinos dodatno se potvrđuje kroz adaptivni ciklus primjene, kojim se razvijeni modeli koriste kao aktivni alati za simulaciju i podršku odlučivanju u realnom vremenu. Time je naglašen potencijal razvijenih alata za proaktivno, prilagodljivo upravljanje građevinskim projektima u složenim i promjenjivim uvjetima.

6.2. Praktični doprinos istraživanja

Praktična vrijednost istraživanja očituje se u razvoju alata koji omogućuje pouzdano predviđanje, smanjuje vrijeme potrebnog prikupljanja i obrade podataka te pruža podršku odlučivanju u fazi izvedbe građevinskih projekata. Integracijom višedioničke perspektive, sveobuhvatne baze podataka i naprednih metoda strojnog učenja razvijen je model koji je robustan, ali prilagođen svakodnevnoj praksi. Njegova osnovna svrha je pravovremeno predviđanje prekoračenja ugovorenog trajanja i iznosa, u fazi kada je još moguće poduzeti korektivne mjere i smanjiti rizik značajnih odstupanja.

Model je koncipiran kao podsustav za upravljanje modelima i predviđen je kao dio šireg sustava za podršku odlučivanju. Korisnicima omogućuje brzo i jednostavno predviđanje odstupanja na temelju unosa ključnih značajki, bez potrebe za dodatnim znanjem o strojnom učenju i bez prikupljanja velikog broja podataka. Dodatna vrijednost je mogućnost izvođenja simulacija „što-ako“ scenarija, čime se unapređuje kvaliteta planiranja i upravljanja projektom.

Prilagodljivost i praktična primjena modela donose izravne koristi svim ključnim dionicima, a najviše izvođačima radova koji snose glavni operativni rizik i raspolažu najrelevantnijim podacima za rad s modelom. Aktivnom primjenom alata izvođač može ranije prepoznati potencijalne probleme, proaktivno prilagođavati resurse i smanjiti odstupanja od planirane dinamike. Osim toga, ovaj pristup šalje jasnu poruku o profesionalnosti, transparentnosti i spremnosti na suradnju, čime se jača povjerenje među dionicima, smanjuje vjerojatnost konflikata i gradi reputacija pouzdanog, odgovornog i inovativnog sudionika.

Razvijeni kod pisan u Jupyter Notebook okruženju omogućuje trenutačno izvođenje simulacija i što-ako analiza. Na taj se način korisnicima pruža praktičan alat i lako primjenjiv za višekratne iteracije, brzo testiranje scenarija i stalno unaprjeđenje modela u stvarnom vremenu.

Iako je razvijen za specifičan lokalni kontekst, pokazuje visok potencijal prilagodbe i za druga tržišta koja dijele slične izazove i strukturu građevinske industrije, čime se otvara prostor za širu regionalnu i međunarodnu primjenu.

Razvijeni model predstavlja konkretan korak prema digitalno podržanom, znanstveno utemeljenom i podatkovno vođenom upravljanju građevinskim projektima, koje omogućuje bolju kontrolu, kvalitetniju suradnju među dionicima i smanjenje rizika neuspjeha u složenim i promjenjivim uvjetima gradilišta.

6.3. Ograničenja i pravci daljnjih istraživanja

Unatoč postignutim rezultatima i širokom potencijalu za primjenu, važno je sagledati određena ograničenja istraživanja kako bi se njegovi nalazi pravilno interpretirali. Jedno od ključnih ograničenja odnosi se na strukturu analiziranog uzorka. Istraživanje je provedeno na bazi podataka od 12 realiziranih građevinskih projekata financiranih javnim sredstvima. Iako se radi o obimnoj i detaljno strukturiranoj bazi podataka, u kontekstu modela temeljenih na dubokom učenju riječ je o relativno ograničenom uzorku. Manji broj podataka može povećati osjetljivost modela na specifične obrasce u uzorku te djelomično ograničiti njegovu sposobnost generalizacije. Ipak, detaljna priprema podataka, uključivanje kategorijskih i numeričkih značajki te višestruka validacija omogućili su postizanje visoke točnosti i stabilnosti, čime je ovaj nedostatak u značajnoj mjeri ublažen.

Sljedeće ograničenje vezano je uz činjenicu da su svi analizirani projekti financirani javnim sredstvima. Specifičnosti javne nabave, ugovornih odnosa i procedura značajno se razlikuju od praksi u privatnom sektoru. Stoga se rezultati, iako metodološki pouzdani, ne mogu automatski preslikati na projekte drugačijeg karaktera. Dodatna istraživanja trebala bi ispitati razinu prilagodbe modela uvjetima privatnih projekata, gdje su dinamika komunikacije, raspodjela rizika i fleksibilnost odlučivanja često bitno drugačiji.

Geografska ograničenost predstavlja još jedan važan izazov. Model je razvijen na temelju podataka s hrvatskog tržišta. Iako je provedena usporedna analiza s nekoliko europskih zemalja slične strukture tržišta, njegova međunarodna primjenjivost zasad ostaje na razini pretpostavke, a ne empirijske potvrde. Globalna primjena obećava, ali zahtijeva daljnju validaciju na uzorcima iz različitih gospodarskih, regulatornih i kulturnih okruženja.

Sva navedena ograničenja ne umanjuju znanstvenu i praktičnu vrijednost modela, ali jasno pokazuju gdje postoji prostor za daljnji razvoj i unaprjeđenje. Sljedeći važan korak trebao bi biti proširenje baze podataka na privatne projekte i različite međunarodne kontekste, čime bi se dodatno provjerila univerzalnost i prilagodljivost pristupa. Važan smjer za širu primjenu modela u praksi je razvoj jednostavnog i intuitivnog korisničkog sučelja koje bi korisnicima omogućilo donošenje informiranih odluka u stvarnom vremenu.

Provedeno istraživanje potvrđuje da kombinacija sustavnog mjerenja performansi, sveobuhvatne analize različitih perspektiva dionika i naprednih metoda strojnog učenja povećava točnost predviđanja i mijenja način na koji razumijemo uspjeh građevinskih projekata. Umjesto oslanjanja isključivo na retrospektivnu analizu, predloženi pristup omogućuje proaktivno upravljanje koje uzima u obzir promjenjive uvjete građevinskih projekata.

POPIS LITERATURE

- Aaltonen, K., Kujala, J. i Oijala, T. (2008) 'Stakeholder salience in global projects', *International Journal of Project Management*, 26, str. 509–516. doi: 10.1016/j.ijproman.2008.05.004
- Abdulhayoglu, M.A. i Thijs, B. (2018) 'Use of locality sensitive hashing (LSH) algorithm to match Web of Science and Scopus', *Scientometrics*, 116, str. 1229–1245. doi: 10.1007/s11192-017-2569-6
- Adam, A., Josephson, P.-E.B. i Lindahl, G. (2017) 'Aggregation of factors causing cost overruns and time delays in large public construction projects', *Engineering, Construction and Architectural Management*, 24(3), str. 393–406. doi: 10.1108/ECAM-09-2015-0135
- Adri, A. i Mursadin, A. (2024) 'Assessing user satisfaction in construction services: Analyzing contractor performance in central Kalimantan's power projects', *World Journal of Advanced Engineering Technology and Sciences*, 11(1), str.105–118. doi: 10.30574/wjaets.2024.11.1.0039
- Agile Manifesto (2001). Dostupno na: <https://www.agilealliance.org/agile101/the-agile-manifesto/> (pristupljeno: 11.3.2025).
- Al Mnaseer, R., Al-Smadi, S. i Al-Bdour, H. (2023) 'Machine learning-aided time and cost overrun prediction in construction projects: application of artificial neural network', *Asian Journal of Civil Engineering*, 24, str. 2583–2593. doi: 10.1007/s42107-023-00665-7
- Alavifar, A.H. i Motamedi, S. (2014) 'Identification, Evaluation and Classification of Time Delay Risks of Construction Project in Iran', *Proceedings of the 2014 International Conference on Industrial Engineering and Operations Management*, Bali, Indonesia, str. 919–929.
- Al-Darrab, I. (2000) 'Relationships between productivity, efficiency, utilisation, and quality', *Work Study*, 49(3), str. 97–104.
- Ali, A.S. i Rahmat, I. (2010) 'The performance measurement of construction projects managed by ISO-certified contractors in Malaysia', *Journal of Retail and Leisure Property*, 9(1), str. 25–35. doi: 10.1057/rlp.2009.20
- Al-Meshekeh, H.S. i Langford, D.A. (1999) 'Conflict management and construction project effectiveness: A review of the literature and development of a theoretical framework', *Journal of Construction Procurement*, 5(1), str. 58–75.
- Alsugair, A., Al-Gahtani, K., Alsanabani, N. M. (2023) 'Artificial Neural Network Model to Predict Final Construction Contract Duration', *Applied Sciences*, 13(14), 8078. doi: 10.3390/app13148078
- Ambrule, V.R. i Bhirud, A.N. (2017) 'Use of artificial neural network for pre design cost estimation of building projects', *International Journal on Recent and Innovation Trends in Computing and Communication*, 5(2), str. 173–176. doi: 10.17762/ijritcc.v5i2.192

- Atkinson, R. (1999) 'Project management: Cost, time and quality, two best guesses and a phenomenon, it's time to accept other success criteria', *International Journal of Project Management*, 17(6), str. 337–342. doi: 10.1016/S0263-7863(98)00069-6
- Au, T. i Hendrickson, C. (1986) 'Profit Measures for Construction Projects', *Journal of Construction Engineering and Management*, 112(2). doi: 10.1061/(ASCE)0733-9364(1986)112:2(273)
- Auma, E. (2014) 'Factors Affecting the Performance of Construction Projects in Kenya: A Survey of Low-Rise Buildings in Nairobi Central Business District', *The International Journal of Business & Management*, 2(12), str. 115–140.
- Aziz, N.A., Mohd-Rahim, F.A. i Aziz, N.M. (2022) 'Systematic literature review on communication in construction project management: Issues among project participants', *Journal of Surveying Construction & Property*, 13, str. 52–70. doi: 10.22452/jscp.sp2022no1.5
- Bakens, W., Foliente, G. i Jasuja, M. (2005) 'Engaging stakeholders in performance-based building: lessons from the Performance-Based Building (PeBBu) Network', *Building Research & Information*, 33(2), str. 149–158. doi: 10.1080/0961321042000322609
- Bassioni, H.A., Price, A.D.F. i Hassan, T.M. (2004) 'Performance Measurement in Construction', *Journal of Management in Engineering*, 20(2), str. 42–50. doi: 10.1061/(ASCE)0742-597X(2004)20:2(42)
- Bernolak, I. (1997) 'Effective measurement and successful elements of company productivity: The basis of competitiveness and world prosperity', *International Journal of Production Economics*, 52(1-2), str. 203–213. doi: 10.1016/S0925-5273(97)00026-1
- Bhaumik, P.K. (2016) 'Developing and Using a New Family of Project S-Curves Using Early and Late Shape Parameters', *Journal of Construction Engineering and Management*, 142(12). doi: 10.1061/(ASCE)CO.1943-7862.0001201
- Bishop, C. M. (1994) 'Neural networks and their applications', *Review of Scientific Instruments*, 65, str. 1803–1832. doi: 10.1063/1.1144830
- Boddy, S., Rezgui, Y., Wetherill, M. i Cooper, G. (2007) 'Knowledge informed decision making in the building lifecycle: An application to the design of a water drainage system', *Automation in Construction*, 16(5), str. 596–606. doi: 10.1016/j.autcon.2006.10.001
- Borcherding, J.D. (1978) 'Improving construction communications', *Project Management Quarterly*, 9(1), str. 50–56.
- Borcherding, J.D., Sebastian, S.J. i Samelson, N.M. (1980) 'Improving Motivation and Productivity on Large Projects', *Journal of the Construction Division*, 106(1), str. 73–89. doi: 10.1061/JCCEAZ.0000865
- Bottazzi, G., Secchi, A. i Tamagni, F. (2008) 'Productivity, profitability and financial performance', *Industrial and Corporate Change*, 17(4), str. 711–751. doi: 10.1093/icc/dtn027
- Bou-Llugar, J.C., Escrig-Tena, A.B., Roca-Puig, V. i Beltran-Martin, I. (2009) 'An empirical assessment of the EFQM Excellence Model: Evaluation as a TQM framework relative to the

- MBNQA Model', *Journal of Operations Management*, 27(1), str. 1–22. doi: 10.1016/j.jom.2008.04.001
- Boussabaine, A.H. i Elhag, T. (1999) 'Applying fuzzy techniques to cash flow analysis', *Construction Management and Economics*, 17, str. 745–755. doi: 10.1080/014461999371088
- Breiman, L. (2001) 'Random Forests', *Machine Learning*, 45, str. 5–32. doi: 10.1023/A:1010933404324
- Bubshait, A.A. i Almohawis, S.A. (1994) 'Evaluating the general conditions of a construction contract', *International Journal of Project Management*, 12(3), str. 133–135.
- Bukoye, O.T., Ejohwomu, O., Roehrich, J. i Too, J. (2022) 'Using nudges to realize project performance management', *International Journal of Project Management*, 40(8), str. 886–905. doi: 10.1016/j.ijproman.2022.10.003
- Burcar Dunović, I., Radujković, M., Vukomanović, M. (2013) 'Razvoj i implementacija registra rizika kod građevinskih projekata', *Građevinar*, 65(1), str. 23–35.
- Car-Pušić, D., Štok, K.T., Petruseva, S. i Zileska-Pancovska, V. (2022) 'Comparative Analysis of Linear Regression and Soft Computing Methods for Estimating Highways Construction Time and Cost in the Republic of Croatia', *15th International OTMC Conference and 6th International Project Management Association Senet Conference*, Dubrovnik, 21–24 September, str. 169–178.
- Cerić, A. (2014) 'Minimizing communication risk in construction: A Delphi study of the key role of project managers', *Journal of Civil Engineering and Management*, 20, str. 829–838. doi: 10.3846/13923730.2013.802739
- Cerić, A. (2016) *Trust in Construction Projects*. London Delhi: Routledge, Taylor & Francis Group
- Cha, H.S. i Kim, C.K. (2011) 'Quantitative approach for project performance measurement on building construction in South Korea', *KSCE Journal of Civil Engineering*, 15(8), str. 1319–1328. doi: 10.1007/s12205-011-1323-5
- Cha, H.S. i Kim, K.H. (2017) 'Measuring Project Performance in Consideration of Optimal Best Management Practices for Building Construction in South Korea', *KSCE Journal of Civil Engineering*, 22(8), str. 1614–1625. doi: 10.1007/s12205-017-0156-2
- Chan, A.P.C. (1996) *Determinants of project success in the construction industry of Hong Kong*. Doktorska disertacija. University of South Australia.
- Chan, A.P.C. i Chan, A.P.L. (2004) 'Key performance indicators for measuring construction success', *Benchmarking: An International Journal*, 11(2), str. 203–221. doi: 10.1108/14635770410532624
- Chan, A.P.C., Scott, D. i Lam, E.W.M. (2002) 'Framework of Success Criteria for Design/Build Projects', *Journal of Management in Engineering*, 18(3). doi: 10.1061/(ASCE)0742-597X(2002)18:3(120)

Chang, R.-D., Zuo, J., Soebarto, V., Zhao, Z.-Y., Zillante, G. i Gan, X. (2017) 'Discovering the Transition Pathways toward Sustainability for Construction Enterprises: Importance-Performance Analysis', *Journal of Construction Engineering and Management*, 143(6), 04017013. doi: 10.1061/(ASCE)CO.1943-7862.0001295

Chao, L.-C. i Chien, C.-F. (2009) 'Estimating Project S-Curves Using Polynomial Function and Neural Networks', *Journal of Construction Engineering and Management*, 135(3), str. 169–177. doi: 10.1061/(ASCE)0733-9364(2009)135:3(169)

Chao, L.-C. i Chien, C.-F. (2010) 'A Model for Updating Project S-curve by Using Neural Networks and Matching Progress', *Automation in Construction*, 19(1), str. 84–91. doi: 10.1016/j.autcon.2009.09.006.

Chen, H.L. (2014) 'Innovation stimulants, innovation capacity, and the performance of capital projects', *Journal of Business Economics and Management*, 15(2), str. 212–231. doi: 10.3846/16111699.2012.711361

Chen, H.L. (2015) 'Performance measurement and the prediction of capital project failure', *International Journal of Project Management*, 33(6), str. 1393–1404. doi: 10.1016/j.ijproman.2015.02.009

Cheng, M.-Y., Tsai, H.-C. i Sudjono, E. (2010) 'Conceptual cost estimates using evolutionary fuzzy hybrid neural network for projects in construction industry', *Expert Systems with Applications*, 37(6), str. 4224–4231. doi: 10.1016/j.eswa.2009.11.080.

Chew, W.B. (1988) 'No-nonsense guide to measuring productivity', *Harvard Business Review*, 66(1), str. 110–118.

Chovichien, V. i Nguyen, T.A. (2013) 'List of indicators and criteria for evaluating construction project success and their weight assignment', *Proceedings of the 4th International Conference on Engineering, Project, and Production Management*, Bangkok, Tajland, 23–25 listopada, str. 130–150.

Chua, D.K.H., Loh, P.K., Kog, Y.C. i Jaselski, E.J. (1997) 'Neural Networks for Construction Project Success', *Expert Systems With Applications*, 13(4), str. 317–328. doi: 10.1016/S0957-4174(97)00046-8

Cicmil, S. i Gaggiotti, H. (2009) 'Who cares about project deadlines? - A processual-relational perspective on problems with information sharing in project environments Knowledge Management', *International Journal of Project Management*, 3(4), str. 222–240. doi: 10.1504/IJKMS.2009.028838

Cyril, E. i Singla, H. (2020) 'Comparative analysis of profitability of real estate, industrial construction and infrastructure firms: evidence from India', *Journal of financial management of property and construction*, 25 (2), str. 273–291.

Cleland, D.I. (1986) 'Project Stakeholder Management', *Project Management Journal*, 17(4), str. 36–44.

Cleland, D.I. (1998) *Stakeholder Management, Project Management Handbook*. Pinto, J.K. (ur.) San Francisco: Jossey-Bass Publishers, str. 55.

Coffie, G.H. i Cudjoe, S.K.F. (2023) 'Toward predictive modelling of construction cost overruns using support vector machine techniques', *Cogent Engineering*, 10(2). doi: 10.1080/23311916.2023.2269656.

Coffie, G.H. i Cudjoe, S.K.F. (2024) 'Using extreme gradient boosting (XGBoost) machine learning to predict construction cost overruns', *International Journal of Construction Management*, 24(16), str. 1742–1750. doi: 10.1080/15623599.2023.2289754.

Cox, R.F., Issa, R.R.A. i Ahrens, D. (2003) 'Management's Perception of Key Performance Indicators for Construction', *Journal of Construction Engineering and Management*, 129(2), str. 142–151. doi: 10.1061/(ASCE)0733-9364(2003)129:2(142)

Danilina, E.I. i Chebotarev, V. (2017) 'Comprehensive assessment of road and communal infrastructure as an important tool for sustainable development of the urban economy', *Theoretical and Empirical Researches in Urban Management*, 12(4), str. 33–51.

Davis, K. (2014) 'Different stakeholder groups and their perceptions of project success', *International Journal of Project Management*, 32, str. 189–201. doi: 10.1016/j.ijproman.2013.02.006

Dawood, N., Sikka, S., Marasini, R. i Dean, J. (2006) 'Development of key performance indicators to establish the benefits of 4D planning', *Proceedings 22nd Annual ARCOM Conference*, 4-6 rujna 2006, Birmingham, UK, Association of Researchers in Construction Management, str. 709–718.

de Wit, A. (1988) 'Measurement of project success', *International Journal of Project Management*, 6(3), str. 164–170. doi: 10.1016/0263-7863(88)90043-9

Demirkesen, S. i Ozorhon, B. (2017a) 'Impact of integration management on construction project management performance', *International Journal of Project Management*, 35(8), str. 1639–1654. doi: 10.1016/j.ijproman.2017.09.008

Demirkesen, S. i Ozorhon, B. (2017b) 'Measuring Project Management Performance: Case of Construction Industry', *Engineering Management Journal*, 29(4), str. 258–277. doi: 10.1080/10429247.2017.1380579

Doloi, H. (2013) 'Cost overruns and failure in project management: Understanding the roles of key stakeholders in construction projects', *Journal of Construction Engineering and Management*, 139(3), str. 267–279. doi: 10.1061/(ASCE)CO.1943-7862.0000621

Donaldson, T. i Preston, L. (1995) 'The stakeholder theory of the corporation: Concepts, evidence, and implications', *The Academy of Management Review*, 20(1), str. 65–91.

Doroshenko, A. (2020) 'Applying Artificial Neural Networks In Construction', *E3S Web of Conferences*, 143, 01029. doi: 10.1051/e3sconf/202014301029

Dwivedi, R., Prasad, K., Mandal, N., Singh, S., Vardhan, M. i Pamučar, D. (2021) 'Performance evaluation of an insurance company using an integrated Balanced Scorecard (BSC) and Best-Worst Method (BWM)', *Decision Making: Applications in Management and Engineering*, 4(1), str. 33–50. doi: 10.31181/dmame2104033d

Dzwigol, H. (2022) 'Comparing idiographic and nomothetic approaches in management sciences research', *Virtual Economics*, 5(4), str. 27–49. doi: 10.34021/ve.2022.05.04(2)

Elhag, T.M.S. i Boussabaine, A.H. (1998) 'An artificial neural system for cost estimation of construction projects', Hughes, W. (ur.) *14th Annual ARCOM Conference*, 9-11 rujna 1998, University of Reading. Association of Researchers in Construction Management, Vol. 1, str. 219–226.

El-Mashaleh, M., Minchin, R.E. i O'Brien, W.J. (2007) 'Management of Construction Firm Performance Using Benchmarking', *Journal of Management in Engineering*, 23(1), str. 10–17. doi: 10.1061/(ASCE)0742-597X(2007)23:1(10)

El-Sawah, H. i Moselhi, O. (2014) 'Comparative study in the use of neural networks for order of magnitude cost estimating in construction', *Journal of Information Technology in Construction*, 19, str. 462–473.

El-Sayegh, S.M. (2008) 'Risk assessment and allocation in the UAE construction industry', *International Journal of Project Management*, 26(4), str. 431–438. doi: 10.1016/j.ijproman.2007.07.004

Enshassi, A. (2003) 'Factors Affecting Safety on Construction Projects', *Environmental Engineering Science*.

Erdogan, B., Anumba, C.J., Bouchlaghem, D. i Nielsen, Y. (2005) 'Change management in construction: The current context', Khosrowshahi, F. (ur.) *21st Annual ARCOM Conference*, 7-9 rujna 2005, SOAS, University of London. Association of Researchers in Construction Management, Vol. 2, str. 1085–1095.

Erzaij, K.R., Burhan, A.M., Hatem, W.A. i Ali, R.H. (2021) 'Prediction of the Delay in the Portfolio Construction Using Naïve Bayesian Classification Algorithms', *Civil and Environmental Engineering*, 17(2), str. 673–680. doi: 10.2478/cee-2021-0066

European Commission (2025) *PM² Methodologies*. Dostupno na: https://pm2.europa.eu/pm2-methodologies_en (pristupljeno: 23. lipnja 2025.).

Eurostat (2024) *Construction Index by NACE Rev. 2 Activity - Quarterly Data*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/ei_isbu_q/default/table?lang=en&category=euroind.ei_is (pristupljeno: 1. listopada 2024.).

Fassin, Y. (2010) 'A dynamic perspective in Freeman's stakeholder model', *Journal of Business Ethics*, 96, str. 39–49.

Fisher, T.J. (1990) 'Business Productivity Measurement Using Standard Cost Accounting Information', *International Journal of Operations & Production Management*, 10(8), str. 61–69. doi: 10.1108/01443579010142243.

Flyvbjerg, B. (2006) 'From Nobel prize to project management: getting risks right', *Project Management Journal*, 37(3), str. 5–15. doi: 10.1177/875697280603700302

Freeman, R.E. (1984) *Strategic Management: A Stakeholder Approach*. Boston, MA, USA: Pitman.

- Freeman, R.E. (1999) 'Response: Divergent Stakeholder Theory', *The Academy of Management Review*, 24(2), str. 233–236. doi: 10.2307/259078
- Galjanić, K., Marović, I. i Hanak, T. (2023) 'Performance Measurement Framework for Prediction and Management of Construction Investments', *Sustainability*, 15(18), 13617. doi: 10.3390/su151813617
- Galjanić, K., Marović, I. i Jajac, N. (2022) 'Decision support systems for managing construction projects: A scientific evolution analysis', *Sustainability*, 14(9), 4977. doi: 10.3390/su14094977
- Gilbert, G.P. (1983) 'The Project Environment', *International Journal of Project Management*, 1(2), str. 83–87. doi: 10.1016/0263-7863(83)90004-2
- Gompertz B. (1825) 'On the Function Expressive of the Law of Human Mortality, and on a new Method of Determining the Value of Life Contingencies', *Philosophical Transactions of the Royal Society*, 115, str. 513-585.
- Goodfellow, I., Bengio, Y. i Courville, A. (2016) *Deep Learning*. Cambridge, MA: MIT Press.
- Grant, M.J. i Booth, A. (2009) 'A typology of reviews: an analysis of 14 review types and associated methodologies', *Health Information & Libraries Journal*, 26(2), str. 91–108. doi: 10.1111/j.1471-1842.2009.00848.x
- Grebic, B. (2019) 'Traditional vs Agile Project Management in the Service Sector', *European Project Management Journal*, 9(2), str. 55–63. doi: 10.18485/epmj.2019.9.2.6
- Grünberg, T. (2004) 'Performance improvement: Towards a method for finding and prioritising potential performance improvement areas in manufacturing operations', *International Journal of Productivity and Performance Management*, 53(1), str. 52–71. doi: 10.1108/17410400410509969
- Guo, Y.-M., Huang, Z.-L., Guo, J., Li, H., Guo, X.-R. i Nkeli, M.J. (2019) 'Bibliometric Analysis on Smart Cities Research', *Sustainability*, 11, 3606. doi: 10.3390/su11133606
- Gyparakis, S., Trichakis, I., Daras, T. i Diamadopoulos, E. (2025) 'Artificial Neural Networks (ANNs) and Multiple Linear Regression (MLR) Analysis Modelling for Predicting Chemical Dosages of a Water Treatment Plant (WTP) of Drinking Water', *Application of Artificial Intelligence (AI) in Water Quality Monitoring*, 17(2), 227. doi: 10.3390/w17020227.
- Hamzah, A.I.N., Lee, C.-K. i Bujna, M. (2024) 'Team performance in the construction industry: A systematic literature review', *International Journal of Industrial Management*, 18(1), str. 1–10. doi: 10.15282/ijim.18.1.2024.10402
- Hartman, F.T. (2002) 'The role of trust in project management', *PMI Research Conference 2000: Project Management Research at the Turn of the Millennium*, Paris, France. Newtown Square, PA: Project Management Institute, str. 225–235.
- He, Q., Wang, T., Chan, A.P.C., Li, H. i Chen, Y. (2019) 'Identifying the gaps in project success research, a mixed bibliographic and bibliometric analysis', *Engineering, Construction and Architectural Management*, 26(8), str. 1553–1573. doi: 10.1108/ECAM-04-2018-0181

Hedeman, B. i Riepma, R. (2023) *Project Management by ICB4* (1. izd.), Zurich, Switzerland: Van Haren Publishing.

Hindradjaja, G.G. i Budiman, J. (2019) 'Financial Performance of Construction, Property, and Trading Companies Based on Working Capital, Liquidity Ratio, and Profitability Ratio', *Advances in civil engineering and sustainable architecture*, 2(1), str. 1–9.

Hughes, D.L., Dwivedi, Y.K. i Rana, N.P. (2017) 'Mapping is failure factors on PRINCE2 stages: An application of interpretive ranking process (IRP)', *Production Planning and Control*, 28(9), str. 776–790. doi: 10.1080/09537287.2017.1311431

Ika, L.A. (2009) 'Project success as a topic in project management journals', *Project Management Journal*, 40(4), str. 6–19. doi: 10.1002/pmj.20137

ILX Group (2025) *PRINCE2 Methodology*. Dostupno na: <https://www.prince2.com/uk/prince2-methodology> (pristupljeno: 11.3.2025).

Islam, M., Chen, G., Jin, S. (2019) 'An Overview of Neural Network', *American Journal of Neural Networks and Applications*, 5(1), str. 7–11. doi: 10.11648/j.ajnna.20190501.12

ISO (2015) *ISO 9000:2015 Quality management systems – Fundamentals and vocabulary*, Geneva: International Organization for Standardization. Dostupno na: <https://www.iso.org/standard/45481.html> (pristupljeno: 11.3.2025).

ISO (2021) *ISO 21500:2021: Project, programme and portfolio management — Context and concepts*, Geneva: International Organization for Standardization. Dostupno na: <https://www.iso.org/standard/75704.html> (pristupljeno: 11.3.2025).

Jackson, M. i Petersson, P. (1999) 'Productivity: An overall measure of competitiveness', *Proceedings of the Second International Workshop on Intelligent Manufacturing Systems*, Leuven: Katholieke Univ. Leuven

Jahan, S., Khan, K.I.A., Thaheem, M.J., Ullah, F., Alqurashi, M., Alsulami, B. (2022) 'Modeling Profitability-Influencing Risk Factors for Construction Projects: A System Dynamics Approach', *Buildings*, 12(6), 701. doi: 10.3390/buildings12060701

Jajac, N. (2010) *Modeliranje sustava za podršku odlučivanju o razvoju i održavanju urbane cestovne infrastrukture*, doktorska disertacija, Ekonomski fakultet, Sveučilište u Splitu

Jelodar, M.B., Wilkinson, S., Kalatehjari, R. i Zou, Y. (2021) 'Designing for construction procurement: An integrated Decision Support System for Building Information Modelling', *Built Environment Project and Asset Management*, 12, str. 111–127. doi: 10.1108/BEPAM-07-2020-0132

Jiang, J.J., Chen, E. i Klein, G. (2002) 'The Importance of Building a Foundation for User Involvement in Information System Projects', *Project Management Journal*, 22(1). doi: 10.1177/875697280203300105

Jóhannesdóttir, R.R. (2019) *Holistic Approach in Project Management*. Diplomski rad. Reykjavík University.

Jonas, D., Kock, A. i Gemünden, H.G. (2013) 'Predicting Project Portfolio Success by Measuring Management Quality-A Longitudinal Study', *IEEE Transactions on Engineering Management*, 60(2), str. 1–12. doi: 10.1109/TEM.2012.2200041

Kagioglou, M., Cooper, R. i Aouad, G. (2001) 'Performance management in construction: A conceptual framework', *Construction Management and Economics*, 19(1), str. 85–95. doi: 10.1080/01446190010003425

Kaka, A.P. i Price, A.D.F. (1991) 'Relationship between value and duration of construction projects', *Construction Management and Economics*, 9(4), str. 383–400. doi: 10.1080/01446199100000030

Kaka, A.P. i Price, A.D.F. (1993) 'Modeling standard cost commitment curves for contractors' cash flow forecasting', *Construction Management and Economics*, 11(4), str. 271–283. doi: 10.1080/01446199300000027

Karlsen, J.T. (1998) *Mestring av omgivelsesusikkerhet – en empirisk studie av prosjekter*, doktorska disertacija, Norwegian University of Science and Technology.

Kärnä, S. (2004) 'Analysing customer satisfaction and quality in construction – the case of public and private customers', *Nordic Journal of Surveying and Real Estate Research*, Special Series, 2.

Kassa, R., Perrin, M., Lines, B., Sullivan, K.T. (2023) 'Measuring Team Effectiveness in Construction Projects: Team Members' Perceptions', *2023 Annual Conference & Exposition*, Baltimore Convention Center, 25.–28. lipnja, 38634.

Keen, P.G.W. i Morton, M.S.S. (1978) *Decision Support Systems: An Organizational Perspective*, Addison-Wesley Publishing Company.

Keenan, M. i Rostami, A. (2019) 'The impact of quality management systems on construction performance in the North West of England', *International Journal of Construction Management*, 21(9), str. 1–13. doi: 10.1080/15623599.2019.1590974

Kelleher, J.D. (2019) *Deep Learning*. Cambridge, MIT Press.

Kelleher, J.D., Tierney, B. (2018) *Data Science*. Cambridge, MIT Press

Kezner, H. i Saladis, F.P. (2009) *Value-Driven Project Management*. Hoboken, New Jersey i Kanada, John Wiley & Sons, Inc.

Kim, B., Reinschmidt, K. (2009) 'Probabilistic Forecasting of Project Duration Using Bayesian Inference and the Beta Distribution', *Journal of Construction Engineering and Management*, 135(3), str. 178–186. doi: 10.1061/(ASCE)0733-9364(2009)135:3(178)

Kim, G.-H., An, S.-H. i Kang, K.-I. (2004) 'Comparison of construction cost estimating models based on regression analysis, neural networks, and case-based reasoning', *Building and Environment*, 39(10), str. 1235–1242. doi: 10.1016/j.buildenv.2004.02.013

- Kim, S.G. (2010) 'Risk performance indexes and measurement systems for mega construction projects', *Journal of Civil Engineering and Management*, 16(4), str. 586–594. doi: 10.3846/jcem.2010.65
- Kim, Y., Choi, T.Y. (2015) 'Deep, sticky, transient, and gracious: An expanded buyer–supplier relationship typology', *Journal of Supply Chain Management*, 51(3), str. 61–86. doi: doi.org/10.1111/jscm.12081
- Kim, Y.S., Kim, M.K., Fu, N., Liu, Y., Wang, J. i Srebric, J. (2025) 'Investigating the impact of data normalization methods on predicting electricity consumption in a building using different artificial neural network models', *Sustainable Cities and Society*, 118, 105570. doi: 10.1016/j.scs.2024.105570
- Kirkman, B.L. i Rosen, B. (1999) 'Beyond self-management: Antecedents and consequences of team empowerment', *Academy of Management Journal*, 42(1), str. 58–74. doi: 10.2307/256874
- Ko, C.-H. i Cheng, M.-Y. (2007) 'Dynamic Prediction of Project Success Using Artificial Intelligence', *Journal of Construction Engineering and Management*, 133(4), str. 316–321. doi: 10.1061/(ASCE)0733-9364(2007)133:4(316)
- Korhonen, T., Jaaskelainen, A., Laine, T. i Saukkonen, N. (2023) 'How performance measurement can support achieving success in project-based operations', *International Journal of Project Management*, 41(1), 102429. doi: 10.1016/j.ijproman.2022.11.002
- Kostelac, D., Marović, I. i Jajac, N. (2016) 'Strategy management control through the balanced scorecard model', *Conference Proceedings of the 35th International Conference on Organizational Science Development*, Kranj: Moderna organizacija, 16–18 ožujka, str. 379–389.
- Kravchunovska, T., Zaiats, Y., Kovalov, V., Nechepurenko, D. i Kirnos, K. (2020) 'Choosing the rational management of high-rise building construction projects', *Eastern-European Journal of Enterprise Technologies*, 3(105), str. 24–33. doi: 10.15587/1729-4061.2020.205135
- Kucharavy, D. i De Guio, R. (2012) 'Application of Logistic Growth Curve', *Procedia Engineering*, 131. doi: 10.1016/j.proeng.2015.12.390
- Laudon, K.C. i Laudon, J.P. (2014) *Management Information Systems: Managing the Digital Firm*. 13th ed. Harlow: Pearson Education.
- LeCun, Y., Bengio, Y. i Hinton, G. (2015) 'Deep learning', *Nature*, 521, str. 436–444. doi: 10.1038/nature14539
- Leon, H., Osman, H., Georgy, M. i Elsaid, M. (2017) 'System dynamics approach for forecasting performance of construction projects', *Journal of Management in Engineering*, 34(1), 04017049. doi: 10.1061/(ASCE)ME.1943-5479.0000575
- Leśniak, A., Juszczak, M. (2018) 'Prediction of site overhead costs with the use of artificial neural network based model', *Archives of Civil and Mechanical Engineering*, 18, str. 973–982.

- Leung, M.-Y., Ng, S.T., Cheung, S.-O. (2004) 'Measuring construction project participant satisfaction', *Construction Management and Economics*, 22(3), str. 319–331. doi: 10.1080/01446190320000000000
- Levy, J.S. (2008) 'Case studies: types, designs, and logics of interference', *Conflict Management and Peace Science*, 25(1), str. 1–18.
- Li, T.H., Ng, S.T. i Skitmore, M. (2013) 'Evaluating stakeholder satisfaction during public participation in major infrastructure and construction projects: a fuzzy approach', *Automation in Construction*, 29, str. 123–135. doi: 10.1016/j.autcon.2012.09.007
- Lin, G. i Shen, Q. (2007) 'Measuring the Performance of Value Management Studies in Construction: Critical Review', *Journal of Management in Engineering*, 23(1), str. 2–9. doi: 10.1061/(ASCE)0742-597X(2007)23:1(2)
- Ling, F.Y.Y., Low, S.P., Wang, S. i Egbelakin, T. (2008) 'Models for Predicting Project Performance in China Using Project Management Practices Adopted by Foreign AEC Firms', *Journal of Construction Engineering and Management*, 134(12), str. 983–990. doi: 10.1061/(ASCE)0733-9364(2008)134:12(983)
- Ling, F.Y.Y., Low, S.P., Wang, S.Q. i Lim, H.H. (2009) 'Key project management practices affecting Singaporean firms' project performance in China', *International Journal of Project Management*, 27(1), str. 59–71. doi: 10.1016/j.ijproman.2007.10.004
- Liu, S., Chang, R., Zuo, J., Webber, R., Xiong, F. i Dong, N. (2021) 'Application of Artificial Neural Networks in Construction Management: Current Status and Future Directions', *Applied Sciences*, 11(20), 9616. doi: 10.3390/app11209616
- Lovrinčević, M., Vukomanović, M. (2022) 'Relationship between costs and perceptions of infrastructure projects', *Građevinar*, 74(3), str. 199–209. doi: 10.14256/JCE.3352.2021
- MacDonald, M. (2002) *Review of Large Public Procurement in the UK*, London: HM Treasury.
- Mallawaarachchi, H. i Senaratne, S. (2015) 'Importance of Quality for Construction Project Success', *6th ICSECM*, str. 84–89.
- Marović, I. (2013) *Sustav za podršku odlučivanju u upravljanju vrijednostima nekretnina*, doktorska disertacija, Građevinski fakultet, Sveučilište u Rijeci.
- Marović, I., Hanak, T. i Plaum, S. (2022) 'Performance management in civil engineering: A systematic literature review', *Elektronički časopis građevinskog fakulteta Osijek*, 24(1), str. 47–58. doi: 10.13167/2022.24.5
- Marović, I., Perić, M. i Hanak, T. (2021) 'A multi-criteria decision support concept for selecting the optimal contractor', *Applied Sciences*, 11(4), 1660. doi: 10.3390/app11041660
- Martín-Martín, A., Orduna-Malea, E., Thelwall, M. i Delgado López-Cózar, E. (2018) 'Google Scholar, Web of Science, and Scopus: A systematic comparison of citations in 252 subject categories', *Journal of Informetrics*, 12(4), str. 1160–1177. doi: 10.1016/j.joi.2018.09.002

McElroy, B. i Mills, C. (2000) *Managing stakeholders*, Turner, R.J. i Sinister, S.J. (ur.) Gower Handbook of Project Management, 3.izd., Gower Publishing Limited, Aldershot, str. 757–775.

McCulloch, W.S., Pitts, W. (1943) 'A logical calculus of the ideas immanent in nervous activity', *Bulletin of Mathematical Biophysics*, 5, str. 115–133. doi: 10.1007/BF02478259

Miller, D.M. (1984) 'Profitability = Productivity + Price Recovery', *Harvard Business Review*, 62, str. 145–153.

Minoja, M. (2012) 'Stakeholder Management Theory, Firm Strategy, and Ambidexterity', *Journal of Business Ethics*, 109(1), str. 67–82. doi: 10.1007/s10551-012-1380-9

Mitchell, R.K., Agle, B.R. i Wood, D.J. (1997) 'Toward a Theory of Stakeholder Identification and Salience: Defining the Principle of Who and What Really Counts', *Academy of Management Review*, 22(4), str. 853–886.

Mladenovic, G., Vajdic, N., Wündsche, B. i Temeljotov Salaj, A. (2013) 'Use of key performance indicators for PPP transport projects to meet stakeholders' performance objectives', *Built Environment Project and Asset Management*, 3(2), str. 228–249. doi: 10.1108/BEPAM-05-2012-0026

Molwus, J.J., Erdogan, B. i Ogunlana, S. (2017) 'Using structural equation modelling (SEM) to understand the relationships among critical success factors (CSFs) for stakeholder management in construction', *Engineering, Construction and Architectural Management*, 24(3), str. 426–450. doi: 10.1108/ECAM-10-2015-0161

Montenegro, A., Dobrota, M., Todorović, M., Slavinski, T. i Obradović, V. (2021) 'Impact of construction project managers' emotional intelligence on project success', *Sustainability*, 13(19), 10804. doi: 10.3390/su131910804

Moradi, S., Ansari, R. i Taherkhani, R. (2021) 'A Systematic Analysis of Construction Performance Management: Key Performance Indicators from 2000 to 2020', *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 46, str. 15–31.

Muller, R., Zhai, L. i Wang, A. (2017) 'Governance and governmentality in projects: Profiles and relationships with success', *International Journal of Project Management*, 35(3), str. 378–392. doi: 10.1016/j.ijproman.2017.01.007

Nannini, G., Warburton, R.D.H. i De Marco, A. (2017) 'Improving the accuracy of project estimates at completion using the Gompertz function', *International Research Network on Organizing by Projects 2017*, UTS ePRESS, Sydney, str. 1–15. doi: 10.5130/pmrp.irnop2017.5670

Naoum, S.G. (1994) 'Critical analysis of time and cost of management and traditional contracts', *Journal of Construction Engineering and Management*, 120(4), str. 687–705. doi: 10.1061/(ASCE)0733-9364(1994)120:4(687)

Narodne novine (2025) *Zakon o gradnji*. Zagreb: Narodne novine d.d., NN 153/13, 20/17, 39/19, 125/19, 145/24

Nasirzadeh, F., Afshar, A. i Khanzadi, M. (2008) 'System dynamics approach for construction risk analysis', *International Journal of Civil Engineering*, 6(2), str. 120–131.

Nassar, N.K. (2009) 'An integrated framework for evaluation of performance of construction projects', *Proceedings of the PMI Global Congress 2009*, North America, Orlando, Florida, 10–13 October, FL. Newtown Square, PA: Project Management Institute.

Nassar, K., Hunnarsson, H.G. i Hegab, M. (2005) 'Using Weibull Analysis for Evaluation of Cost and Schedule Performance', *Journal of Construction Engineering and Management*, 131(12). doi: 10.1061/(ASCE)0733-9364(2005)131:12(1257)

Nassar, N. i AbouRizk, S. (2014) 'Practical Application for Integrated Performance Measurement of Construction Projects', *Journal of Management in Engineering*, 30(6), 04014027. doi: 10.1061/(ASCE)ME.1943-5479.0000287

Newcombe, R. (2003) 'From client to project stakeholders: A stakeholder mapping approach', *Construction Management and Economics*, 21(8), str. 841–848. doi: 10.1080/0144619032000072137

Norouzi, M., Chàfer, M., Cabeza, L.F., Jiménez, L. i Boer, D. (2021) 'Circular economy in the building and construction sector: A scientific evolution analysis', *Journal of Building Engineering*, 44, 102704. doi: 10.1016/j.jobe.2021.102704

Obi, C.D., Chukwuma, P.O., Igbokwe, C.P., Ibeakuzie, P.O. i Ifeanyi, A.C. (2024) 'A Novel Extension of Rayleigh Distribution: Characterization, Estimation, Simulations and Applications', *Journal of Xidian University*, 18(7), str. 177–188. doi: 10.5281/Zenodo.12664617

Obianyo, J.I., Okey, O.E. i Alaneme, G.U. (2022) 'Assessment of cost overrun factors in construction projects in Nigeria using fuzzy logic', *Innovative Infrastructure Solutions*, 7(5). doi: 10.1007/s41062-022-00908-7

Omar, M.N. i Fayek, A.R. (2016) 'Modeling and evaluating construction project competencies and their relationship to project performance', *Automation in Construction*, 69, str. 115–130. doi: 10.1016/j.autcon.2016.05.021

Oppong, G.D., Chan, A.P.C. i Dansoh, A. (2017) 'A review of stakeholder management performance attributes in construction projects', *International Journal of Project Management*, 35(6), str. 1037–1051. doi: 10.1016/j.ijproman.2017.04.015

Ostojić-Škomrlj, N. i Radujković, M. (2012) 'Model prognoziranja S-krivulja u ranim fazama građevinskih projekata', *Građevinar*, 64(8), str. 647–654.

Othman, A.A.E. (2014) 'An International Index for Customer Satisfaction in the Construction Industry', *Journal of Construction Engineering and Project Management*, 4(4), str. 17–32. doi: 10.6106/JCEPM.2014.4.4.017

Pamučar, D., Macura, D., Tavana, M., Božanić, D. i Knežević, N. (2022) 'An integrated rough group multicriteria decision-making model for the ex-ante prioritization of infrastructure projects: The Serbian Railways case', *Socio-Economic Planning Sciences*, 79, 101098. doi: 10.1016/j.seps.2021.101098

Park, H.-S. (2006) 'Conceptual framework of construction productivity estimation', *KSCSE Journal of Civil Engineering*, 10(5), str. 311–317. doi: 10.1007/BF02830084

Parker, S.K. i Skitmore, M. (2005) 'Project management turnover: Causes and effects on project performance', *International Journal of Project Management*, 23(3), str. 205–214. doi: 10.1016/j.ijproman.2004.10.004

Patrucco, A.S., Moretto, A. i Knight, L. (2021) 'Does relationship control hinder relationship commitment? The role of supplier performance measurement systems in construction infrastructure projects', *International Journal of Production Economics*, 233, 108000. doi: 10.1016/j.ijpe.2020.108000

Pavez, I., Gomez, H., Liu, C. i Gonzalez, V.A. (2022) 'Measuring project team performance: A review and conceptualization', *International Journal of Project Management*, 40(8), str. 951–971. doi: 10.1016/j.ijproman.2022.11.001

Peer, S. (1982) 'Application of Cost-Flow Forecasting Models', *Journal of Construction Division*, 108, str. 226–232.

Pekuri, A., Haapasalo, H. i Herrala, M. (2011) 'Productivity and performance management – Managerial practices in the construction industry', *International Journal of Performance Measurement*, 1, str. 39–58.

Peško, I., Trivunić, M., Ćirović, G. i Mučenski, V. (2013) 'A preliminary estimate of time and cost in urban road construction using neural networks', *Tehnički vjesnik - Technical Gazette*, 20(3), str. 563–570.

Petruseva, S., Zujo, V. i Zileska-Pancovska, V. (2012) 'Neural Network Prediction Model for Construction Project Duration', *International Journal of Engineering Research and Technology*, 1(2).

Phillips, R. (2009) *Stakeholder Theory and Organizational Ethics*. San Francisco: Berrett-Koehler Publishers, Inc.

PMI (2004) *A Guide to the Project Management Body of Knowledge*. 3rd Edition, PMI, Newtown Square

PMI (2021) *Pulse of the Profession 2021: Beyond Agility*. Dostupno na: https://www.pmi.org/-/media/pmi/documents/public/pdf/learning/thought-leadership/pulse/pmi_pulse_2021.pdf (pristupljeno: 5.1.2025.)

Pollack, J. i Adler, D. (2015) 'Emergent trends and passing fads in project management research: a scientometric analysis of changes in the field', *International Journal of Project Management*, 33(1), str. 236–248. doi: 10.1016/j.ijproman.2014.04.011

Post, J.E., Preston, L.E. i Sachs, S. (2002) 'Managing the extended enterprise: The new stakeholder view', *California Management Review*, 45(1), str. 6–28. doi: 10.2307/41166151

Prebanić, K.R. i Vukomanović, M. (2023) 'Exploring Stakeholder Engagement Process as The Success Factor for Infrastructure Projects', *Buildings*, 13(7), 1785. doi: 10.20944/preprints202304.1002.v1

Rad, H.N. i Khosrowshahi, F. (1998) 'Quality measurement in construction projects', *14th Annual ARCOM Conference*, 9.-11. rujna 1998., University of Reading Association of Researchers in Construction Management, 2, str. 389–397.

Radujković, M., Sjekavica Klepo, M. i Bosch-Rekveltdt, M. (2021) 'Breakdown of Engineering Projects' Success Criteria', *Journal of Construction Engineering and Management*, 147(11), 04021144. doi: 10.1061/(ASCE)CO.1943-7862.0002168

Rajala, P., Ylä-Kujala, A., Sinkkon, T. i Kärri, T. (2022) 'Profitability in construction: how does building renovation business fare compared to new building business', *Construction Management and Economics*, 40(3), str. 223–237. doi: 10.1080/01446193.2022.2032228

Rankin, J., Fayek, A.R., Meade, G., Haas, C. i Mandeau, A. (2008) 'Initial metrics and pilot program results for measuring the performance of the Canadian construction industry', *Canadian Journal of Civil Engineering*, 35(9), str. 894–907. doi: 10.1139/L08-018

Rezaei, A.R., Celik, T. i Baalousha, Y. (2011) 'Performance measurement in a quality management system', *Scientia Iranica*, 18(3), str. 742–752. doi: 10.1016/j.scient.2011.05.021

Rogulj, K., Jajac, N. i Simic, F. (2017) 'A Decision Support Concept for a construction design project – selecting the type of glass façade', *Croatian Operational Research Review*, 8(1), str. 333–350. doi: 10.17535/corr.2017.0021

Rosenblatt, F. (1958) 'The perceptron: A probabilistic model for information storage and organization in the brain', *Psychological Review*, 65(6), str. 386–408. doi: 10.1037/h0042519

Rožić, T. (2018) 'Affect regulation in psychotherapy supervision: A multiple case study of moments of change', *Ljetopis socijalnog rada*, 25(3), str. 403–425. doi: 10.3935/ljsr.v25i3.245

Rumelhart, D.E., Hinton, G.E. i Williams, R.J. (1986) 'Learning representations by back-propagating errors', *Nature*, 323(9), str. 533–536.

Safa, M., Sabet, A., MacGillivray, S., Davidson, M., Kaczmarczyk, K., Haas, C.T., Gibson, G.E. i Rayside, D. (2015) 'Classification of Construction Projects', *International Journal of Civil, Environmental, Structural, Construction and Architectural Engineering*, 9(6), str. 625–633.

Santana, G. (1990) 'Classification of construction projects by scales of complexity', *Project Management*, 8(2), str. 102–104. doi: 10.1016/0263-7863(90)90044-C

Savage, G.T., Nix, T.W., Whitehead, C.J. i Blair, J.D. (1991) 'Strategies for Assessing and Managing Organizational Stakeholders', *Academy of Management Executive*, 5(2), str. 61–75. doi: 10.2307/4165008

Scott-Young, C. i Samson, D. (2008) 'Project success and project team management: evidence from capital projects in the process industries', *Journal of Operations Management*, 26(6), str. 749–766. doi: 10.1016/j.jom.2007.10.006

Seawright, J. i Gerring, J. (2008) 'Case selection techniques in case study research: a menu of qualitative and quantitative options', *Political Research Quarterly*, 61(2), str. 294–308. doi: 10.1177/1065912907313077

Senouci, A., Ismail, A. i Eldin, N. (2016) 'Time Delay and Cost Overrun in Qatari Public Construction Projects', *Procedia Engineering*, 164, str. 368–375. doi: 10.1016/j.proeng.2016.11.632

Serra, C.E.M. i Kunc, M. (2015) 'Benefits realization management and its influence on project success and on the execution of business strategies', *International Journal of Project Management*, 33(1), str. 53–66. doi: 10.1016/j.ijproman.2014.03.011

Sertyesilisik, B. (2017) 'A preliminary study on the regenerative construction project management concept for enhancing sustainability performance of the construction industry', *International Journal of Construction Management*, 17(4), str. 1–17. doi: 10.1080/15623599.2016.1222665

Shihadeh, J., Al-Shainie, G., Bisharah, M., Alshami, D., Alkhadrawi, S., Al-Bdour, H. (2024) 'Evaluation and prediction of time overruns in Jordanian construction projects using coral reefs optimization and deep learning methods', *Asian Journal of Civil Engineering*, 25, str.2665-2677

Sikavica, P., Hunjak, T., Begičević Ređep, N. i Hernaus, T. (2014) *Poslovno odlučivanje*, Zagreb: Školska knjiga.

Silva, G.A., Warnakulasuriya, B.N.F. i Arachchige, B. (2016) 'Criteria for Construction Project Success: A Literature Review', *SSRN Electronic Journal*. doi: 10.2139/ssrn.2910305

Singh, J.K. i Jain, M. (2013) 'A study of employees' job satisfaction and its impact on their performance', *Journal of Indian Research*, 1(4), str. 105–111.

Singh, S., Kanli, A.I. i Sevgen, S. (2016) 'A general approach for porosity estimation using artificial neural network method: a case study from Kansas gas field', *Studia Geophysica et Geodaetica*, 60, str. 130–140. doi: 10.1007/s11200-015-0820-2

Sink, D.S. i Tuttle, T.C. (1989) *Planning and Measurement in your Organization of the Future*, Norcross, GA: Industrial Engineering and Management Press.

Skibniewski, M.J. i Ghosh, S. (2009) 'Determination of Key Performance Indicators with Enterprise Resource Planning Systems in Engineering Construction Firms', *Journal of Construction Engineering and Management*, 135(10), str. 965–978. doi: 10.1061/(ASCE)0733-9364(2009)135:10(965)

Soetanto, R. i Proverbs, D.G. (2004) 'Intelligent models for predicting levels of client satisfaction', *Journal of Construction Research*, 5(2), str. 233–253. doi: 10.1142/S1609945104000164

Songer, A.D. i Molenaar, K.R. (1997). 'Project characteristics for successful public sector design-build', *Journal of Construction Engineering and Management*, 123(1), str. 34–40.

Stanojlovic, D. i Cirovic, G. (2016) 'Analysis of the success of a construction project with regard to the S-curve', *International Scientific Conference People, Buildings and Environment 2016 (PBE2016)*, 29 rujna-1 listopada, Luhacovice, Republika Češka

Šestan, M., Arsov, T., Kifer, N., Frković, M., Grgurić, D., Barišić, S., Ellyard, J., Cook, M., Vinuesa, Carola G., Jelušić, M. (2022) 'Primjena sekvenciranja cijelog egzoma u bolesnika sa sistemskim

eritemskim lupusom koji započinje u dječjoj dobi – višestruka studija slučaja', *Reumatizam*, str. 32–33. doi: 10.33004/reumatizam-sup-69-1-4

Tabassi, A.A. i Bakar, A.H.A. (2009) 'Training, motivation, and performance: the case of human resource management in construction projects in Mashhad, Iran', *International Journal of Project Management*, 27(5), str. 471–480. doi: 10.1016/j.ijproman.2008.08.002

Tam, C.M. i Harris, F. (1996) 'Model for assessing building contractors' project performance', *Engineering, Construction and Architectural Management*, 3(3), str. 187–203.

Tam, C.M., Tong, T.K.L., Leung, A.W.T., Chiu, G.W.C. i Leung, W.T.A. (2002) 'Site Layout Planning using Nonstructural Fuzzy Decision Support System', *Journal of Construction Engineering and Management*, 128(3), str. 220–231. doi: 10.1061/(ASCE)0733-9364(2002)128:3(220)

Tangen, S. (2005) 'Demystifying productivity and performance', *International Journal of Productivity and Performance Management*, 54(1), str. 34–46. doi: 10.1108/17410400510571437

Tijanić Štrok, K. i Car-Pušić, D. (2017) 'Use of S-Curve in Construction Projects', *Common Foundations 2017 Conference Proceedings*. doi: 10.5592/CO/ZT.2017.05

Tijanić Štrok, K., Car-Pušić, D., Šperac, M. (2019) 'Cost estimation in road construction using artificial neural network', *Neural Computing and Applications*, 32, str. 9343–9355

Toor, S.-R. i Ogunlana, S.O. (2010) 'Beyond the "iron triangle": Stakeholder perception of key performance indicators (KPIs) for large-scale public sector development projects', *International Journal of Project Management*, 28(3), str. 228–236. doi: 10.1016/j.ijproman.2009.05.005

Torrecilla-Garcia, J.A., Pardo-Ferreira, M.C. i Rubio-Romero, J.C. (2021) 'Overall Introduction to the Framework of BIM-based Digital Twinning in Decision-making in Safety Management in Building Construction Industry', *Direccion y Organizacion*, 74, str. 31–38. doi: 10.37610/DYO.V0I74.600

Trijeti, Irwanto, R., Rahayu, T. i Panudju, A.T. (2023) 'Artificial Neural Networks for Construction Project Cost and Duration Estimation', *Revue d'Intelligence Artificielle*, 37(6), str. 1449–1460. doi: 10.18280/ria.370609

Tripathi, K.K. i Jha, K.N. (2018) 'An Empirical Study on Performance Measurement Factors for Construction Organizations', *KSCE Journal of Civil Engineering*, 22, str. 1052–1066. doi: 10.1007/s12205-017-1892-z

Turban, E., Sharda, R., Delen, D. i King, D. (2011) *Business Intelligence: A Managerial Approach*, 2.izd., New Jersey: Pearson Education Inc.

Turner, R. i Zolin, R. (2012) 'Forecasting success on large projects: Developing reliable scales to predict multiple perspectives by multiple stakeholders over multiple time frames', *Project Management Journal*, 43(5), str. 87–99. doi: 10.1002/pmj.21289

- Velumani, P., Nampoothiri, N.V.N. i Mariusz, U. (2021) 'A Comparative Study of Models for the Construction Duration Prediction in Highway Road Projects of India', *Sustainability*, 13(8), 4552. doi: 10.3390/su13084552
- Vidal, L. i Marle, F. (2008) 'Understanding project complexity: Implications on project management', *Kybernetes*, 37(8), str. 1094–1110. doi: 10.1108/03684920810884928
- Vukomanović, M. i Radujković, M. (2013) 'The balanced scorecard and EFQM working together in a performance management framework in construction industry', *Journal of Civil Engineering and Management*, 19(5), str. 683–695. doi: 10.3846/13923730.2013.799090
- Wadi, M. (2023) *An empirical investigation into wind energy modeling: A case study utilizing five distributions and four advanced optimization methods*. A. Fekik, M. Ghanes, & H. Denoun (Eds.), *Power Electronics Converters and their Control for Renewable Energy Applications*, str. 237–263. doi: 10.1016/B978-0-323-91941-8.00011-1
- Wanberg, J., Harper, C., Hallowell, M. i Rajendran, S. (2013) 'Relationship between Construction Safety and Quality Performance', *Journal of Construction Engineering and Management*, 139(10), 04013003. doi: 10.1061/(asce)co.1943-7862.0000732
- Wang, Q., El-Gafy, M. i Zha, J. (2010) 'Bi-Level Framework for Measuring Performance to Improve Productivity of Construction Enterprises', *Proceedings of the Construction Research Congress 2010: Innovation for Reshaping Construction Practice*, Banff, Kanada, 8–10 svibnja. doi: 10.1061/41109(373)97
- Ward, S. i Chapman, C. (2008) 'Stakeholders and uncertainty management in projects', *Construction Management and Economics*, 26(6), str. 563–577. doi: 10.1080/01446190801998708
- Wauters, M. i Vanhoucke, M. (2016) 'A Comparative Study of Artificial Intelligence Methods for Project Duration Forecasting', *Expert Systems with Applications*, 46, str. 249–261. doi: 10.1016/j.eswa.2015.10.008
- Wawak, S., Ljevo, Ž. i Vukomanović, M. (2020) 'Understanding the Key Quality Factors in Construction Projects—A Systematic Literature Review', *Sustainability*, 12(24), 10376. doi: 10.3390/su122410376
- Wibowo, M.A., Astana, I.N.Y. i Rusdi, H.A. (2017) 'Dynamic Modelling of the Relation between Bidding Strategy and Construction Project Performance', *Procedia Engineering*, 171, str. 341–347. doi: 10.1016/j.proeng.2017.01.342
- Williams, T. (2016) 'Identifying success factors in construction projects: A case study', *Project Management Journal*, 47(1), str. 97–112. doi: 10.1002/pmj.21558
- Williams, T., Vo, H., Bourne, M., Bourne, P., Cooke-Davies, T., Kirkham, R., Masterton, G., Quattrone, P., Valette, J. (2020) 'A cross-national comparison of public project benefits management practices—the effectiveness of benefits management frameworks in application', *Production Planning and Control*, 31, str. 644–65. doi: 10.1080/09537287.2019.1668980
- Winch, G.M. (2010) *Managing Construction Projects: An Information Processing Approach*. 2. izd. Oxford, UK: Wiley-Blackwell.

Winn, M. (2001) 'Building stakeholder theory with a decision modeling methodology', *Business & Society*, 40(2), str. 133–166. doi: 10.1177/000765030104000202

Wonguri, P. i Park, J.K. (2023) 'Prediction of Wastewater Treatment Plant Effluent Water Quality Using Recurrent Neural Network (RNN) Models', *Wastewater Engineering: Wastewater Treatment Methods and Technologies*, 15(19), 3325. doi: 10.3390/w15193325

Xiao, H. i Proverbs, D. (2013) 'Factors influencing contractor performance: an international investigation', *Engineering, Construction and Architectural Management*, 10(5), str. 322–332. doi: 10.1108/09699980310502937

Xue, H., Zhang, S., Su, Y., Wu, Z. i Yang, R.Y. (2018) 'Effect of stakeholder collaborative management on off-site construction cost performance', *Journal of Cleaner Production*, 184, str. 490–502. doi: 10.1016/j.jclepro.2018.02.258

Yang, J., Shen, G.Q., Ho, M., Drew, D.S. i Xue, X. (2011) 'Stakeholder management in construction: an empirical study to address research gaps in previous studies', *International Journal of Project Management*, 29(7), str. 900–910. doi: 10.1016/j.ijproman.2010.07.013

Yang, R.Y., Jayasuriya, S., Gunarathna, C., Arashpour, M., Xue, X. i Zhang, G. (2018) 'The evolution of stakeholder management practices in Australian mega construction projects', *Engineering, Construction and Architectural Management*, 25(6), str. 690–706. doi: 10.1108/ECAM-07-2016-0168

Yildiz, K. i Ahi, M.T. (2020) 'Innovative decision support model for construction supply chain performance management', *Production Planning & Control*, 33(9-10), str. 894–906. doi: 10.1080/09537287.2020.1837936

Yin, R.K. (2018) *Case Study Research and Applications: Design and Methods*. Thousand Oaks, CA, USA: SAGE Publications.

Young, T.L. (2006) *Successful Project Management*. 2. izd., UK: Kogan Page.

Zhang, X. (2005) 'Critical Success Factors for Public–Private Partnerships in Infrastructure Development', *Journal of Construction Engineering and Management*, 131(1), str. 3–14. doi: 10.1061/(ASCE)0733-9364(2005)131:1(3)

PRILOZI

Prilog A: Kod za razvoj modela predviđanja prekoračenja ugovorenog trajanja i iznosa

Prilog B: Ulazni podatci modela predviđanja prekoračenja ugovorenog trajanja i iznosa

Prilog C: Kod za razvoj modela predviđanja krivulje kumulativnog napretka

Prilog D: Ulazni podatci modela predviđanja kumulativne krivulje napretka

Prilog A: Kod za razvoj modela predviđanja prekoračenja ugovorenog trajanja i iznosa

```
import numpy as np
import tensorflow as tf
import random
import pandas as pd
from sklearn.model_selection import KFold, train_test_split
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Input
from tensorflow.keras.optimizers import Adam, SGD, RMSprop
from tensorflow.keras.regularizers import l2
import os
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Input, BatchNormalization
import json
import joblib
import matplotlib.pyplot as plt
import seaborn as sns
# Fiksiranje random seeda
SEED = 42
os.environ['PYTHONHASHSEED'] = str(SEED)
np.random.seed(SEED)
random.seed(SEED)
tf.random.set_seed(SEED)
# Deterministički način rada za TensorFlow
os.environ['TF_CUDNN_DETERMINISTIC'] = '1'
os.environ['TF_DETERMINISTIC_OPS'] = '1'
tf.config.threading.set_inter_op_parallelism_threads(1)
tf.config.threading.set_intra_op_parallelism_threads(1)
tf.data.experimental.enable_debug_mode()
# Učitavanje podataka
file_path = r"C:\Users\Kristina\Desktop\NN_prekoracenje_vremena.xlsx"
data = pd.read_excel(file_path)
X = data.drop(columns=["Prekoračenje vremena"])
y = data["Prekoračenje vremena"]
# Preprocesiranje (standardizacija i enkodiranje)
from sklearn.preprocessing import StandardScaler, OneHotEncoder
```

```

from sklearn.compose import ColumnTransformer
numeric_features = X.select_dtypes(include=["int64", "float64"]).columns.tolist()
categorical_features = X.select_dtypes(include=["object"]).columns.tolist()
preprocessor = ColumnTransformer([
    ("num", StandardScaler(), numeric_features),
    ("cat", OneHotEncoder(), categorical_features)])
X_transformed = preprocessor.fit_transform(X)
y = y.reset_index(drop=True)
X_transformed = np.asarray(X_transformed)
data = data.sort_values(by=data.columns.tolist()).reset_index(drop=True)
# Funkcije za metrike
def smape(y_true, y_pred):
    numerator = np.abs(y_true - y_pred)
    denominator = (np.abs(y_true) + np.abs(y_pred)) / 2
    return 100 * np.mean(numerator / denominator)
def mape(y_true, y_pred):
    return 100 * np.mean(np.abs((y_true - y_pred) / (y_true + 1e-8)))
# RANDOM FOREST ZA ZNAČAJKE
rf = RandomForestRegressor(n_estimators=100, random_state=SEED)
rf.fit(X_transformed, y)
feature_importance = rf.feature_importances_
sorted_features = np.argsort(feature_importance)[::-1]
np.save("sorted_features.npy", sorted_features)
# Definiranje brojeve značajki koje će se testirati
num_features_list = [3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22]
# Značajke nakon preprocesiranja
feature_names = (
    [f"num_{col}" for col in numeric_features] +
    list(preprocessor.transformers_[1][1].get_feature_names_out(categorical_features)))
# Ispis značajki i njihove važnosti
print("Važnost značajki:")
for i in sorted_features:
    print(f"Značajka: {feature_names[i]}, Važnost: {feature_importance[i]:.4f}")
# Definiranje modela
def build_model(input_dim, num_layers, neurons_layer1, neurons_layer2, dropout1,
dropout2, activation, learning_rate):
    model = Sequential()
    model.add(Input(shape=(input_dim,)))
    model.add(Dense(neurons_layer1, activation=activation,
kernel_regularizer=l2(0.01)))

```

```

    model.add(Dropout(dropout1))
    if num_layers == 2:
        model.add(Dense(neurons_layer2, activation=activation,
kernel_regularizer=l2(0.01)))
        model.add(Dropout(dropout2))
        model.add(Dense(1, activation="linear"))
        model.compile(optimizer=Adam(learning_rate=learning_rate),
loss="mean_squared_error")
        return model
# Odabir slučajnih hiperparametara
def random_hyperparameter_selection(hyperparameter_space):
    num_layers = np.random.choice(hyperparameter_space["num_layers"])
    neurons_layer1 = np.random.choice(hyperparameter_space["neurons_layer1"])
    neurons_layer2 = (
        np.random.choice([n for n in hyperparameter_space["neurons_layer2"] if n <=
neurons_layer1])
        if num_layers > 1 else None)
    return {
        "num_layers": num_layers,
        "neurons_layer1": neurons_layer1,
        "neurons_layer2": neurons_layer2,
        "dropout1": np.random.choice(hyperparameter_space["dropout1"]),
        "dropout2": np.random.choice(hyperparameter_space["dropout2"]) if num_layers
> 1 else None,
        "learning_rate": np.random.choice(hyperparameter_space["learning_rate"]),
        "activation": np.random.choice(hyperparameter_space["activation"]),}
# Definiranje raspona hiperparametara
hyperparameter_space = {
    "num_layers": [1, 2],
    "neurons_layer1": [8, 16, 32, 40],
    "neurons_layer2": [8, 16, 32, 40],
    "dropout1": [0.0, 0.1, 0.2, 0.3],
    "dropout2": [0.0, 0.1, 0.2, 0.3],
    "learning_rate": [0.001, 0.005, 0.01],
    "activation": ["relu", "tanh", "sigmoid", "elu"]}
# K-FOLD KRIŽNA VALIDACIJA
# Petlja za testiranje različitog broja značajki, optimizaciju arhitekture i
hiperparametara neuronske mreže
kf = KFold(n_splits=3, shuffle=True, random_state=SEED)
all_results = []

```

```

# Početak mjerenja vremena
import time
start_time = time.time()
best_overall_score = float("inf")
best_overall_params = None
best_metrics = None
for num_features in num_features_list:
    print(f"Testiranje s {num_features} značajki")
    num_features = min(num_features, X_transformed.shape[1])
    X_subset = X_transformed[:, sorted_features[:num_features]]
    best_score = float("inf")
    best_params = None
    best_metrics = {}
    n_trials = 30
    for trial in range(n_trials):
        params = random_hyperparameter_selection(hyperparameter_space)
        print(f"Trial {trial + 1}: {params}")
        fold_metrics = {"MSE": [], "RMSE": [], "MAE": [], "MAPE": [], "SMAPE": [], "R²": []}
        for train_index, test_index in kf.split(X_subset):
            X_train, X_val = X_subset[train_index], X_subset[test_index]
            y_train, y_val = y.iloc[train_index], y.iloc[test_index]
            tf.keras.backend.clear_session()
            model = build_model(
                input_dim=X_train.shape[1],
                num_layers=params["num_layers"],
                neurons_layer1=params["neurons_layer1"],
                neurons_layer2=params["neurons_layer2"],
                dropout1=params["dropout1"],
                dropout2=params["dropout2"],
                activation=params["activation"],
                learning_rate=params["learning_rate"])
            model.fit(X_train, y_train, epochs=50, batch_size=16, verbose=0, shuffle=False)
            y_pred_fold = model.predict(X_val).flatten()
            mse = mean_squared_error(y_val, y_pred_fold)
            rmse = np.sqrt(mse)
            mae = mean_absolute_error(y_val, y_pred_fold)
            mape_score = mape(y_val, y_pred_fold)
            smape_score = smape(y_val, y_pred_fold)
            r2 = r2_score(y_val, y_pred_fold)
            fold_metrics["MSE"].append(mse)

```

```

        fold_metrics["RMSE"].append(rmse)
        fold_metrics["MAE"].append(mae)
        fold_metrics["MAPE"].append(mape_score)
        fold_metrics["SMAPE"].append(smape_score)
        fold_metrics["R2"].append(r2)
    avg_mse = np.mean(fold_metrics["MSE"])
    if avg_mse < best_score:
        best_score = avg_mse
        best_params = params
        best_metrics = fold_metrics
        # Spremanje modela
        model_filename =
f"D:/Python_vrijeme/best_model_{num_features}_features.keras"
        model.save(model_filename)
        print(f"Novi najbolji model spremljen: {model_filename} s MSE:
{best_score:.4f}")
        hyperparam_filename =
f"D:/Python_vrijeme/best_params_{num_features}_features.json"
        for key, value in best_params.items():
            if isinstance(value, np.integer):
                best_params[key] = int(value)
            elif isinstance(value, np.floating):
                best_params[key] = float(value)
        with open(hyperparam_filename, "w") as f:
            json.dump(best_params, f, indent=4)
        print(f" Hiperparametri spremljeni u {hyperparam_filename}")
    if best_metrics is None:
        print(f" Upozorenje")
        continue
    # Čuvanje najboljeg modela za ovaj broj značajki
    all_results.append({
        "Num Features": num_features,
        "MSE": np.mean(best_metrics["MSE"]),
        "RMSE": np.mean(best_metrics["RMSE"]),
        "MAE": np.mean(best_metrics["MAE"]),
        "MAPE": np.mean(best_metrics["MAPE"]),
        "SMAPE": np.mean(best_metrics["SMAPE"]),
        "R2": np.mean(best_metrics["R2"]),
        "Num Layers": best_params["num_layers"] if best_params else None,
        "Neurons Layer 1": best_params["neurons_layer1"] if best_params else None,

```

```

        "Neurons Layer 2": best_params["neurons_layer2"] if best_params else None,
        "Dropout 1": best_params["dropout1"] if best_params else None,
        "Dropout 2": best_params["dropout2"] if best_params else None,
        "Learning Rate": best_params["learning_rate"] if best_params else None,
        "Activation": best_params["activation"] if best_params else None})
# Zaustavljanje mjerenja vremena
end_time = time.time()
total_time = end_time - start_time # Trajanje u sekundama
# Snimanje rezultata u Excel
best_results_df = pd.DataFrame(all_results)
output_file = "rezultati_znacajki_kfold_vrijeme.xlsx"
best_results_df.to_excel(output_file, index=False)
print(f"\n Najbolji modeli su spremjeni u Excel: {output_file}")
# Ispis trajanja izvršavanja
print(f"\n Ukupno vreme izvršavanja: {total_time:.2f} sekundi")
# TRENING OPTIMALNE NEURONSKE MREŽE
# Učitavanje podataka
file_path = r"C:\Users\Kristina\Desktop\NN_prekoracenje_vremena.xlsx"
data = pd.read_excel(file_path)
# Razdvajanje X (ulazi) i y (ciljne vrijednosti)
X = data.drop(columns=["Prekoračenje vremena"])
y = data["Prekoračenje vremena"]
# Podjela na train (80 %) i test (20 %)
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
# Učitavanje prethodno spremljenog preprocesora i transformacija podataka
preprocessor_filename = "D:/Python_vrijeme/preprocessor.pkl"
preprocessor = joblib.load(preprocessor_filename)
X_train_transformed = preprocessor.transform(X_train)
X_test_transformed = preprocessor.transform(X_test)
# Odabir samo 10 najboljih značajki
sorted_features = np.load("sorted_features.npy")
num_features = 10
selected_feature_indices = sorted_features[:num_features]
X_train_selected = X_train_transformed[:, selected_feature_indices]
X_test_selected = X_test_transformed[:, selected_feature_indices]
print(f" Oblik train skupa: {X_train_selected.shape}")
print(f" Oblik test skupa: {X_test_selected.shape}")
# Definicija modela
model = Sequential([
    Dense(40, activation='tanh', input_shape=(num_features,))

```

```

    Dense(1, activation="linear") ])
model.compile(optimizer=Adam(learning_rate=0.005), loss="mean_squared_error")
# Treniranje modela
history = model.fit(X_train_selected, y_train, epochs=100, batch_size=16,
validation_data=(X_test_selected, y_test), verbose=1)
print(" Model je uspješno istreniran!")
# EVALUACIJA I VIZUALIZACIJA REZULTATA
# Predviđanje na testnom skupu
y_pred = model.predict(X_test_selected).flatten()
# Izračunaj metrike
mse = mean_squared_error(y_test, y_pred)
rmse = np.sqrt(mse)
mae = mean_absolute_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)
print("\n Rezultati modela na neviđenom testnom skupu:")
print(f"MSE: {mse:.4f}")
print(f"RMSE: {rmse:.4f}")
print(f"MAE: {mae:.4f}")
print(f"R2 Score: {r2:.4f}")
plt.plot(history.history['loss'], label='Train Loss')
plt.plot(history.history['val_loss'], label='Validation Loss')
plt.xlabel('Epoha')
plt.ylabel('MSE')
plt.legend()
plt.title('Gubitak modela kroz epohe')
plt.show()
# DODATNA OPTIMIZACIJA NEURONSKE MREŽE
# Učitavanje spremljenih značajki i hiperparametara
sorted_features = np.load("sorted_features.npy")
best_params_path = "D:/Python_vrijeme/best_params_10_features_tanh40.json"
with open(best_params_path, "r") as f:
    best_params = json.load(f)
num_features = 10
X_subset = X_transformed[:, sorted_features[:num_features]]
# Učitavanje spremljenog modela
best_model_path = "D:/Python_vrijeme/best_model_10_features.keras"
model = tf.keras.models.load_model(best_model_path)
print(f" Učitani model iz {best_model_path} s {num_features} značajki")
#Zadržavanje težina i pokretanje nove optimizacije

```

```

def build_model(input_dim, num_layers, neurons_layer1, neurons_layer2, dropout1,
dropout2, activation, learning_rate, weight_path=None):
    model = Sequential()
    model.add(Input(shape=(input_dim,)))
    model.add(Dense(neurons_layer1, activation=activation))
    model.add(Dropout(dropout1))
    if num_layers == 2:
        model.add(Dense(neurons_layer2, activation=activation))
        model.add(Dropout(dropout2))
    model.add(Dense(1, activation="linear"))
    model.compile(optimizer=Adam(learning_rate=learning_rate),
loss="mean_squared_error")
    # Učitavanje težina
    if weight_path:
        model.load_weights(weight_path)
        print(f" Učitane težine iz {weight_path}")
    return model

# Učitavanje spremljenih značajki i modela
best_model_path = "D:/Python_vrijeme/best_model_10_features_tanh40.keras"
best_params_path = "D:/Python_vrijeme/best_params_10_features_tanh40.json"
with open(best_params_path, "r") as f:
    best_params = json.load(f)

# Podjela X_transformed na train i test skup
X_train, X_test, y_train, y_test = train_test_split(X_transformed, y, test_size=0.2,
random_state=42)

# Odabir samo 10 najboljih značajki
X_train_selected = X_train[:, sorted_features[:num_features]]
X_test_selected = X_test[:, sorted_features[:num_features]]

# Provjera dimenzija
print(f" X_train_selected shape: {X_train_selected.shape}")
print(f" X_test_selected shape: {X_test_selected.shape}")

# Učitavanje modela
model = tf.keras.models.load_model(best_model_path)
print(f" Učitani model iz {best_model_path} s {num_features} značajki")

# Treniranje svih slojeva
for layer in model.layers:
    layer.trainable = False

# Definiranje hiperparametre za fine-tuning
fine_tune_learning_rates = [0.001, 0.003, 0.005, 0.007]
fine_tune_dropout_rates = [0.0, 0.05, 0.1, 0.15]

```

```

fine_tune_batch_sizes = [16]
optimizers = {
    "Adam": Adam,
    "SGD": lambda lr: SGD(learning_rate=lr, momentum=0.9),
    "RMSprop": lambda lr: RMSprop(learning_rate=lr)}
# Evaluacija modela
def evaluate_model(y_true, y_pred):
    mse = mean_squared_error(y_true, y_pred)
    rmse = np.sqrt(mse)
    mae = mean_absolute_error(y_true, y_pred)
    mape = 100 * np.mean(np.abs((y_true - y_pred) / (y_true + 1e-8)))
    smape = 100 * np.mean(2 * np.abs(y_true - y_pred) / (np.abs(y_true) +
np.abs(y_pred) + 1e-8))
    r2 = r2_score(y_true, y_pred)
    return mse, rmse, mae, mape, smape, r2
# Pohrana rezultata
all_results = []
best_mse = float("inf")
best_params = None
print(f"Model input shape: {model.input_shape}")
print(f"X_train_selected shape: {X_train_selected.shape}")
# Testiranje različitih hiperparametara
for lr in fine_tune_learning_rates:
    for dropout in fine_tune_dropout_rates:
        for batch_size in fine_tune_batch_sizes:
            for opt_name, opt_func in optimizers.items():
                print(f" Testing: LR={lr}, Dropout={dropout}, Batch={batch_size},
Optimizer={opt_name}")
                # Model za svaku iteraciju
                model = Sequential([
                    Input(shape=(num_features,)),
                    Dense(40, activation='tanh'),
                    Dropout(dropout),
                    Dense(1, activation="linear")])
                optimizer = opt_func(lr)
                model.compile(optimizer=optimizer, loss="mean_squared_error")
                history = model.fit(X_train_selected, y_train, epochs=50,
batch_size=batch_size,
                                validation_data=(X_test_selected, y_test),
                                verbose=0, shuffle=True)

```

```

y_pred = model.predict(X_test_selected).flatten()
mse, rmse, mae, mape, smape, r2 = evaluate_model(y_test, y_pred)
all_results.append({
    "Learning Rate": lr,
    "Dropout": dropout,
    "Batch Size": batch_size,
    "Optimizer": opt_name,
    "MSE": mse,
    "RMSE": rmse,
    "MAE": mae,
    "MAPE": mape,
    "SMAPE": smape,
    "R2": r2})
print(f" MSE = {mse:.4f}, RMSE = {rmse:.4f}, MAE = {mae:.4f}, MAPE = {mape:.2f}%, SMAPE = {smape:.2f}%, R2 = {r2:.4f}")
if mse < best_mse:
    best_mse = mse
    best_params = {"learning_rate": lr, "dropout": dropout, "batch_size": batch_size, "optimizer": opt_name}
    model.save("D:/Python_vrijeme/fine_tuned_model_vrijeme.keras")
print(f"\n Najbolji MSE: {best_mse:.4f} s parametrima {best_params}")
# Spremanje rezultata u DataFrame
results_df = pd.DataFrame(all_results)
# VIZUALIZACIJA REZULTATA
# Generiranje predviđanja
y_pred_test = model.predict(X_test_selected).flatten()
# Scatter plot
plt.figure(figsize=(7,5))
sns.scatterplot(x=y_test, y=y_pred_test, alpha=0.7)
plt.plot([min(y_test), max(y_test)], [min(y_test), max(y_test)], linestyle='--', color='red')
plt.xlabel("Stvarne vrijednosti")
plt.ylabel("Predviđanja")
plt.title("Scatter plot: Stvarne vrijednosti vs. Predviđanja (Test set)")
plt.show()
# Gubitak kroz epohe
test_loss = model.evaluate(X_test_selected, y_test, verbose=0)
plt.figure(figsize=(7,5))
plt.plot(history.history['loss'], label='Train Loss', color="blue")

```

```

plt.axhline(y=test_loss, color='red', linestyle='dashed', label=f"Test Loss =
{test_loss:.4f}")
plt.xlabel("Epohe")
plt.ylabel("Loss (MSE)")
plt.title("Praćenje gubitka kroz epohe (Train & Test Loss)")
plt.legend()
plt.show()
# Histogram grešaka predviđanja
residuals = y_test - y_pred_test
plt.figure(figsize=(7,5))
sns.histplot(residuals, bins=10, kde=True)
plt.xlabel("Greška predviđanja (Reziduali)")
plt.ylabel("Broj podataka")
plt.title("Histogram grešaka predviđanja")
plt.show()
# Predviđanja na trening skupu
y_pred_train = model.predict(X_train_selected).flatten()
plt.figure(figsize=(7,5))
plt.plot(range(len(y_train)), y_train, label="Stvarne vrijednosti (Train)", marker="o",
linestyle="None", alpha=0.6)
plt.plot(range(len(y_train)), y_pred_train, label="Predviđanja (Train)", marker="x",
linestyle="None", alpha=0.6)
plt.xlabel("Podatci")
plt.ylabel("Vrijednost")
plt.title("Predviđanja na trening skupu")
plt.legend()
plt.show()
# Predviđanja na test skupu
plt.figure(figsize=(7,5))
plt.plot(range(len(y_test)), y_test, label="Stvarne vrijednosti (Test)", marker="o",
linestyle="None", alpha=0.6)
plt.plot(range(len(y_test)), y_pred_test, label="Predviđanja (Test)", marker="x",
linestyle="None", alpha=0.6)
plt.xlabel("Podatci")
plt.ylabel("Vrijednost")
plt.title("Predviđanja na test skupu")
plt.legend()
plt.show()
# Boxplot grešaka predviđanja na test skupu
residuals = y_test - y_pred_test

```

```

plt.figure(figsize=(7,5))
sns.boxplot(x=residuals)
plt.axvline(x=0, color='red', linestyle='dashed')
plt.xlabel("Rezidualne greške (y_test - y_pred)")
plt.title("Boxplot grešaka predviđanja na test skupu")
plt.show()

# Rezidualne greške modela
residuals = y_test - y_pred_test
plt.scatter(y_test, residuals)
plt.axhline(y=0, color='r', linestyle='dashed')
plt.xlabel("Stvarne vrijednosti")
plt.ylabel("Greška predviđanja (y_test - y_pred)")
plt.title("Rezidualne greške modela")
plt.show()

# Distribucija ciljne varijable
plt.hist(y_test, bins=10, edgecolor="black")
plt.xlabel("Stvarne vrijednosti")
plt.ylabel("Broj podataka")
plt.title("Distribucija y_test")
plt.show()

# Stvarne vrijednosti vs predviđanja
plt.scatter(y_test, y_pred_test)
plt.plot([min(y_test), max(y_test)], [min(y_test), max(y_test)], '--r') # Idealna linija
plt.xlabel("Stvarne vrijednosti")
plt.ylabel("Predviđanja ")
plt.title("Stvarne vrijednosti vs. Predviđanja ")
plt.show()

# Usporedba stvarnih vrijednosti i predviđanja
# Provjera broj podataka
num_samples = len(y_test)
plt.figure(figsize=(8, 5))
sns.histplot(y_test, label="Stvarne vrijednosti", kde=True, bins=10, color="blue",
alpha=0.5)
sns.histplot(y_pred, label="Predviđanja modela", kde=True, bins=10, color="orange",
alpha=0.5)
plt.xlabel("Vrijednost ciljne varijable")
plt.ylabel("Gustoća / Frekvencija")
plt.title("Usporedba stvarnih vrijednosti i predviđanja")
plt.legend()
plt.show()

```

```

# DataFrame za usporedbu
df_results = pd.DataFrame({
    "Stvarne vrijednosti (y_test)": y_test,
    "Predviđanja (y_pred_test)": y_pred_test})
# Prikaz podataka
print(" Usporedba stvarnih vrijednosti i predviđanja:")
print(df_results.head(10))
# VALIDACIJA MODELA
# Putanja do spremljenog modela i hiperparametara
model_path =
"D:/Python_trosak/fine_tuned_model_trosak_7_features_pocetak_relu.keras"
params_path =
"D:/Python_trosak/best_fine_tuned_params_7_features_pocetak_relu.json"
# Učitavanje modela
model = tf.keras.models.load_model(model_path)
print("\n Model uspješno učitano!")
# Ispis arhitekture modela
model.summary()
# Učitavanje spremljenih hiperparametara
with open(params_path, "r") as f:
    best_params = json.load(f)
print("\n Hiperparametri modela:")
for key, value in best_params.items():
    print(f"{key}: {value}")
# Broj značajki na temelju prethodne optimizacije
num_features = 10
X_subset = X_transformed[:, sorted_features[:num_features]]
y_subset = y.values
# 3-fold križna validacija
kf = KFold(n_splits=3, shuffle=True, random_state=42)
all_results = []
fold = 1
for train_index, test_index in kf.split(X_subset):
    print(f"\n Fold {fold}...")
    X_train, X_test = X_subset[train_index], X_subset[test_index]
    y_train, y_test = y_subset[train_index], y_subset[test_index]
    # Ponovno učitavanje modela za svaki fold kako bi se resetirale težine
    model = tf.keras.models.load_model(model_path)
    # Treniranje modela samo na train skupu
    model.fit(X_train, y_train, epochs=50, batch_size=16, verbose=0)

```

```

# Predviđanja na test skupu
y_pred = model.predict(X_test).flatten()
# Izračun metrika
mse = mean_squared_error(y_test, y_pred)
rmse = np.sqrt(mse)
mae = mean_absolute_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)
smape_score = smape(y_test, y_pred)
print(f" Fold {fold} - MSE: {mse:.4f}, RMSE: {rmse:.4f}, MAE: {mae:.4f}, SMAPE:
{smape_score:.2f}%, R2: {r2:.4f}")
all_results.append({
    "Fold": fold,
    "MSE": mse,
    "RMSE": rmse,
    "MAE": mae,
    "SMAPE": smape_score,
    "R2": r2})
fold += 1
# Prikaz prosječnih rezultata
print("\n Prosječni rezultati na 3-fold križnoj validaciji:")
avg_mse = np.mean([r["MSE"] for r in all_results])
avg_rmse = np.mean([r["RMSE"] for r in all_results])
avg_mae = np.mean([r["MAE"] for r in all_results])
avg_smape = np.mean([r["SMAPE"] for r in all_results])
avg_r2 = np.mean([r["R2"] for r in all_results])
print(f" Prosječan MSE: {avg_mse:.4f}")
print(f" Prosječan RMSE: {avg_rmse:.4f}")
print(f" Prosječan MAE: {avg_mae:.4f}")
print(f" Prosječan SMAPE: {avg_smape:.2f}%")
print(f" Prosječan R2: {avg_r2:.4f}")

```

Prilog B: Ulazni podatci modela predviđanja prekoračenja ugovorenog trajanja i iznosa

P	T1	T2	T3	V1	V2	V3	F1	F2	F3	U	K	UP	AD	PR	OT	TR	IO	SN	FZ	US	ZS	ZI	PI	PT
P1,1	0	0	1	0	0	1	1	0	0	0,2024	0,6095	-0,3664	1,0944	-1,8094	-0,8980	0,5225	-1,0442	1,6026	0,2705	-0,2106	0,1400	0,0874	0,8796	1,0998
P1,2	0	0	1	0	0	1	0	1	0	0,2024	0,8063	0,5758	1,6572	-1,8094	0,1123	1,9797	0,4016	-0,4980	1,3525	-1,8950	0,1400	-0,9611	0,8796	1,0998
P1,3	0	0	1	0	0	1	0	0	1	0,2024	0,5857	0,5758	3,0729	-0,1175	0,7529	2,2798	-1,0442	-0,9923	0,2705	-1,8950	0,1400	-0,9611	0,8796	1,0998
P2,1	0	1	0	1	0	0	1	0	0	-0,7421	-0,7127	-1,3086	-0,5252	-0,1175	-0,9413	-0,7089	-1,0442	-0,0038	-1,8935	-0,2106	0,1400	0,0874	-0,0237	0,2685
P2,2	0	1	0	1	0	0	0	1	0	-0,7421	-0,6730	0,5758	-0,7157	-0,1175	-0,2491	-0,6786	-1,0442	-0,5598	-0,8115	1,4739	0,9802	1,1358	-0,0237	0,2685
P2,3	0	1	0	1	0	0	0	0	1	-0,7421	-0,6367	0,5758	0,1282	-0,1175	0,7499	-0,6181	-1,0442	1,6026	-0,8115	0,6317	0,1400	1,1358	-0,0237	0,2685
P3,1	0	1	0	1	0	0	1	0	0	0,7810	2,3062	-2,2507	-0,1358	-0,1175	-1,1916	0,3979	1,8474	0,8949	-1,8935	-0,2106	0,9802	1,1358	0,0463	0,4825
P3,2	0	1	0	1	0	0	0	1	0	0,7810	3,0622	-1,3086	-1,1031	-0,9634	-0,3640	2,0582	1,8474	0,7376	-0,8115	-1,0528	-0,7001	-2,0095	0,0463	0,4825
P3,3	0	1	0	1	0	0	0	0	1	0,7810	1,9652	-0,3664	0,3563	-0,1175	0,8747	2,7223	1,8474	1,2319	2,4345	0,6317	0,9802	-0,9611	0,0463	0,4825
P4,1	1	0	0	0	0	1	1	0	0	-1,0758	-0,7127	-0,3664	0,8957	0,7285	-0,7194	-0,7089	-1,0442	-0,9923	0,2705	-0,2106	0,9802	1,1358	0,1710	0,3644
P4,2	1	0	0	0	0	1	0	1	0	-1,0758	-0,7127	-0,3664	0,2108	0,7285	0,3387	-0,7089	0,4016	-0,9923	0,2705	0,6317	0,9802	1,1358	0,1710	0,3644
P4,3	1	0	0	0	0	1	0	0	1	-1,0758	0,2570	0,5758	0,7631	0,7285	1,3025	0,6817	0,4016	-0,9923	0,2705	1,4739	0,9802	1,1358	0,1710	0,3644
P5,1	1	0	0	0	0	1	1	0	0	0,8791	-0,7127	0,5758	-1,6061	-0,1175	-0,5536	-0,7089	0,4016	-0,9923	0,2705	1,4739	-1,5403	0,0874	0,3730	0,3201
P5,2	1	0	0	0	0	1	0	1	0	0,8791	-0,6757	1,5179	0,7088	0,7285	1,0007	-0,6607	0,4016	1,6026	0,2705	-0,2106	-1,5403	-0,9611	0,3730	0,3201
P5,3	1	0	0	0	0	1	0	0	1	0,8791	-0,5846	1,5179	1,4216	0,7285	1,8756	-0,4936	0,4016	2,0351	0,2705	-0,2106	0,9802	0,0874	0,3730	0,3201
P6,1	0	1	0	0	1	0	1	0	0	-1,0441	-0,7127	1,5179	-1,5681	-0,9634	-1,6011	-0,7089	-1,0442	-0,9923	0,2705	0,6317	-2,3805	-2,0095	0,0024	0,0000
P6,2	0	1	0	0	1	0	0	1	0	-1,0441	-0,7127	1,5179	-0,8311	-0,1175	-0,8986	-0,7089	0,4016	-0,9923	-0,8115	0,6317	-2,3805	-0,9611	0,0024	0,0000
P6,3	0	1	0	0	1	0	0	0	1	-1,0441	-0,7127	1,5179	0,2135	0,7285	0,8242	-0,7089	0,4016	0,1610	0,2705	-0,2106	-1,5403	-0,9611	0,0024	0,0000
P7,1	0	0	1	1	0	0	1	0	0	1,3796	0,1485	-1,3086	0,5287	-0,1175	-1,1538	-0,5019	-1,0442	0,7376	0,2705	0,6317	0,9802	0,0874	-0,3100	0,0340
P7,2	0	0	1	1	0	0	0	1	0	1,3796	2,1124	-0,3664	-0,5004	0,7285	-0,1153	0,7849	0,4016	0,1610	2,4345	0,6317	0,1400	-0,9611	-0,3100	0,0340
P7,3	0	0	1	1	0	0	0	0	1	1,3796	1,0994	-0,3664	-0,8049	0,7285	1,0240	0,8223	1,8474	-0,4156	0,2705	1,4739	0,1400	-0,9611	-0,3100	0,0340
P8,1	1	0	0	1	0	0	1	0	0	0,2062	-0,1432	0,5758	-1,1833	-1,8094	-1,7393	-0,6398	-1,0442	-0,3003	-1,8935	-0,2106	-1,5403	0,0874	0,0974	0,6973
P8,2	1	0	0	1	0	0	0	1	0	0,2062	-0,1295	1,5179	0,3469	-0,9634	-0,0858	-0,2212	-1,0442	0,7376	-1,8935	-1,8950	-1,5403	-0,9611	0,0974	0,6973
P8,3	1	0	0	1	0	0	0	0	1	0,2062	0,1679	-0,3664	0,5231	0,7285	1,0880	0,4746	0,4016	0,3917	1,3525	0,6317	0,1400	0,0874	0,0974	0,6973
P9,1	1	0	0	0	0	1	1	0	0	-0,6980	-0,7127	-2,2507	-1,6039	-1,8094	-1,4964	-0,7089	-1,0442	0,7376	0,2705	-1,8950	-0,7001	-2,0095	0,1261	0,4783
P9,2	1	0	0	0	0	1	0	1	0	-0,6980	-0,7127	-1,3086	-0,9357	-0,1175	-0,1761	-0,7089	0,4016	-0,5852	-0,8115	-0,2106	0,1400	0,0874	0,1261	0,4783
P9,3	1	0	0	0	0	1	0	0	1	-0,6980	0,3688	-0,3664	0,6168	1,5744	1,1751	0,7827	0,4016	2,4675	0,2705	0,6317	0,1400	0,0874	0,1261	0,4783
P10,1	0	0	1	0	1	0	1	0	0	1,9184	-0,7127	0,5758	-0,9185	0,7285	-1,5918	-0,7089	1,8474	-0,9923	0,2705	-0,2106	0,9802	1,1358	0,0208	0,4754
P10,2	0	0	1	0	1	0	0	1	0	1,9184	-0,7127	0,5758	-1,2229	1,5744	-0,7215	-0,7089	0,4016	-0,2639	-0,8115	-1,0528	0,9802	1,1358	0,0208	0,4754
P10,3	0	0	1	0	1	0	0	0	1	1,9184	-0,7127	0,5758	0,2056	1,5744	0,8173	-0,7089	-1,0442	-0,9923	0,2705	-0,2106	0,9802	1,1358	0,0208	0,4754
P11,1	1	0	0	0	1	0	1	0	0	-0,7755	-0,7127	-0,3664	-0,2409	-1,8094	-0,5508	-0,7089	0,4016	-0,0038	0,2705	1,4739	0,1400	1,1358	-0,0017	0,5664
P11,2	1	0	0	0	1	0	0	1	0	-0,7755	-0,3601	-0,3664	0,1090	-0,1175	0,7332	-0,2900	-1,0442	-0,9923	0,2705	1,4739	0,1400	1,1358	-0,0017	0,5664
P11,3	1	0	0	0	1	0	0	0	1	-0,7755	-0,3601	-0,3664	0,2000	1,5744	0,8124	-0,2779	-1,0442	-0,9923	0,2705	-0,2106	0,9802	1,1358	-0,0017	0,5664
P12,1	1	0	0	0	0	1	1	0	0	-1,0311	-0,7127	-0,3664	-0,5662	-0,9634	-0,9372	-0,7089	0,4016	-0,0038	0,2705	-1,0528	0,1400	0,0874	0,2266	0,8172
P12,2	1	0	0	0	0	1	0	1	0	-1,0311	-0,7127	-0,3664	0,4652	-0,1175	1,0432	-0,7089	0,4016	-0,5598	-0,8115	-1,0528	0,1400	0,0874	0,2266	0,8172
P12,3	1	0	0	0	0	1	0	0	1	-1,0311	0,7638	-0,3664	0,9441	0,7285	1,4600	1,5090	-1,0442	-0,9923	0,2705	-0,2106	0,1400	0,0874	0,2266	0,8172

Prilog C: Kod za razvoj modela predviđanja krivulje kumulativnog napretka

```
import os
import numpy as np
import pandas as pd
import tensorflow as tf
import json
import random
import pickle
from tensorflow.keras import backend as K
from sklearn.metrics import mean_absolute_error, mean_absolute_percentage_error,
r2_score
import matplotlib.pyplot as plt
from keras_tuner import HyperModel
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Input
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping
from tensorflow.keras.regularizers import l2
from sklearn.model_selection import train_test_split
from keras_tuner.tuners import RandomSearch
import seaborn as sns
from sklearn.model_selection import KFold
# Fiksiranje random seed-a za Numpy, TensorFlow i Python
SEED = 42
random.seed(SEED)
np.random.seed(SEED)
tf.random.set_seed(SEED)
# Deterministički način rada za TensorFlow
os.environ['PYTHONHASHSEED'] = str(SEED)
os.environ['TF_DETERMINISTIC_OPS'] = '1'
os.environ['CUDA_VISIBLE_DEVICES'] = "-1"
# UVOZ I UČITAVANJE BAZE PODATAKA
file_path = r'C:\Users\Kristina\Desktop\ulazni_krivulja_2.xlsx'
data = pd.read_excel(file_path)
```

```

print(data.head())
# Priprema baze podataka
# Dummy encoding
nominal_columns = ['tip']
dummy_encoded_data = pd.get_dummies(data[nominal_columns], drop_first=False)
processed_data = pd.concat([data.drop(columns=nominal_columns),
dummy_encoded_data], axis=1)
# Min-max normalizacija
numerical_columns = ['ugovoreni iznos', 'realizirani iznos', 'prekoracenje vremena',
'prekoracenje troska']
normalization_bounds = {}
for col in numerical_columns:
    normalization_bounds[col] = {
        'min': data[col].min(),
        'max': data[col].max()}
with open('normalization_bounds.json', 'w') as f:
    json.dump(normalization_bounds, f)
processed_data[numerical_columns] = (
    processed_data[numerical_columns] - data[numerical_columns].min()
) / (data[numerical_columns].max() - data[numerical_columns].min())
# Definiranje ciljane varijable
X = processed_data.drop(columns=['segment trosak'])
y = processed_data['segment trosak']
# Podjela podataka na trening i test skup
X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.2, random_state=SEED)
# Definiranje strukture neuronske mreže i parametara za optimizaciju
class NeuralNetworkHyperModel(HyperModel):
    def __init__(self, input_dim):
        self.input_dim = input_dim
    def build(self, hp):
        model = Sequential()
        model.add(Input(shape=(self.input_dim,)))
        for i in range(hp.Int('layers', 1, 2)):

```

```

        model.add(Dense(
            units=hp.Int(f'units_{i}', min_value=8, max_value=32, step=8),
            activation='relu'))
        model.add(Dropout(hp.Float(f'dropout_{i}', 0.0, 0.2, step=0.1)))
        model.add(Dense(1, activation='linear'))
        model.compile(
            optimizer=Adam(learning_rate=hp.Choice('learning_rate', [0.001, 0.005,
0.002])),
            loss='mean_squared_error',
            metrics=['mae'])
        return model
# Postavljanje HyperModel-a
input_dim = X_train.shape[1]
hypermodel = NeuralNetworkHyperModel(input_dim=input_dim)
# Keras Tuner RandomSearch
tuner = RandomSearch(
    hypermodel,
    objective='val_loss',
    max_trials=20,
    executions_per_trial=2,
    seed=42,
    directory='my_tuner_dir17',
    project_name='hyperparameter_optimization17')
early_stopping = EarlyStopping(monitor='val_loss', patience=5)
# Pokretanje optimizacije
tuner.search(
    X_train, y_train,
    validation_split=0.2,
    epochs=50,
    batch_size=16,
    callbacks=[early_stopping],
    verbose=1)
# Najbolji hiperparametri
best_hps = tuner.get_best_hyperparameters(num_trials=1)[0]

```

```

print("Najbolji hiperparametri:")
print(f"- Broj slojeva: {best_hps.get('layers')}")
for i in range(best_hps.get('layers')):
    print(f" - Sloj {i+1}: {best_hps.get(f'units_{i}')} neurona, dropout {best_hps.get(f'dropout_{i}')}")
print(f"- Learning rate: {best_hps.get('learning_rate')}")
# TRENIRANJE KONAČNOG MODELA
final_model = tuner.hypermodel.build(best_hps)
history = final_model.fit(
    X_train, y_train,
    validation_split=0.2,
    epochs=50,
    batch_size=16,
    callbacks=[early_stopping],
    verbose=1)
# Evaluacija na test skupu
loss, mae = final_model.evaluate(X_test, y_test, verbose=1)
print(f"Test Loss: {loss}")
print(f"Test MAE: {mae}")
# Predviđanja na test skupu
y_pred = final_model.predict(X_test)
y_test_np = y_test.to_numpy() if not isinstance(y_test, np.ndarray) else y_test
y_pred_np = y_pred.flatten()
# Definicija dodatnih metrika
# RMSE
def root_mean_squared_error(y_true, y_pred):
    return np.sqrt(np.mean((y_pred - y_true) ** 2))
# MAPE
epsilon = 1e-8
def mean_absolute_percentage_error(y_true, y_pred):
    y_true = np.maximum(y_true, epsilon)
    return np.mean(np.abs((y_true - y_pred) / y_true)) * 100
# R²
r_squared = r2_score(y_test, y_pred)

```

```

# Prikaz metrika
print(f"R2 (koeficijent determinacije): {r_squared}")
print(f"RMSE: {root_mean_squared_error(y_test_np, y_pred_np)}")
print(f"MAPE: {mean_absolute_percentage_error(y_test_np, y_pred_np)}")

# VIZUALIZACIJE KONAČNOG MODELA

# Vizualizacija gubitka tijekom treninga i validacije
plt.plot(history.history['loss'], label='Gubitak tijekom treniranja')
plt.plot(history.history['val_loss'], label='Gubitak tijekom validacije')
plt.xlabel('Epohe')
plt.ylabel('Gubitak')
plt.title('Gubitak tijekom treniranja i validacije')
plt.legend()
plt.show()

# Stvarne vrijednosti vs predviđanja
plt.figure(figsize=(8, 6))
plt.scatter(y_test, y_pred, alpha=0.5, label='Predviđanja')
plt.plot([0, 1], [0, 1], color='red', linestyle='--', label='Idealna linija')
plt.xlabel("Stvarne vrijednosti")
plt.ylabel("Predviđanja ")
plt.title("Stvarne vrijednosti vs Predviđanja ")
plt.legend()
plt.show()

# Rezidualni graf (greške)
residuals = y_test - y_pred
plt.scatter(y_test, residuals, alpha=0.5)
plt.axhline(0, color='red', linestyle='--')
plt.xlabel('Predviđene vrijednosti')
plt.ylabel('Reziduali')
plt.title('Rezidualni graf')
plt.show()

# Histogram rezidualnih grešaka
plt.hist(residuals, bins=20, edgecolor='k', alpha=0.7)
plt.xlabel('Reziduali')
plt.ylabel('Frekvencija')

```

```

plt.title('Distribucija grešaka')
plt.show()
# Histogram predviđanja i stvarnih vrijednosti
plt.figure(figsize=(8, 6))
sns.histplot(y_test, color="blue", kde=True, label="Stvarne vrijednosti", stat="density")
sns.histplot(y_pred.flatten(), color="orange", kde=True, label="Predviđanja ",
stat="density")
plt.xlabel("Vrijednosti")
plt.ylabel("Frekvencija")
plt.title("Distribucija stvarnih vrijednosti i predviđanja")
plt.legend()
plt.show()
# Box plot stvarnih vrijednosti i predviđanja
plt.figure(figsize=(8, 6))
sns.boxplot(data=[y_test.values, y_pred], palette="Set2")
plt.xticks([0, 1], ["Stvarne vrijednosti", "Predviđanja"])
plt.title("Box plot stvarnih vrijednosti i predviđanja")
plt.show()
# Kumulativna distribucija apsolutnih grešaka
sorted_errors = np.sort(np.abs(y_test - y_pred))
cumulative = np.arange(1, len(sorted_errors) + 1) / len(sorted_errors)
plt.figure(figsize=(8, 6))
plt.plot(sorted_errors, cumulative, label="Kumulativna distribucija grešaka")
plt.axvline(np.median(sorted_errors), color='red', linestyle='--', label='Medijan greške')
plt.title("Kumulativna distribucija apsolutnih grešaka")
plt.xlabel("Apsolutna greška")
plt.ylabel("Kumulativni postotak")
plt.legend()
plt.show()
# KRIŽNA VALIDACIJA
kf = KFold(n_splits=5, shuffle=True, random_state=42)
cv_rmse = []
cv_mae = []
cv_mape = []

```

```

cv_r2 = []
all_y_val = []
all_y_val_pred = []
for train_index, val_index in kf.split(X):
    X_train, X_val = X.iloc[train_index], X.iloc[val_index]
    y_train, y_val = y.iloc[train_index], y.iloc[val_index]
    model = final_model
    model.fit(X_train, y_train, epochs=50, batch_size=16, verbose=0)
    y_val_pred = model.predict(X_val).flatten()
    rmse = np.sqrt(mean_squared_error(y_val, y_val_pred))
    mae = mean_absolute_error(y_val, y_val_pred)
    mape = mean_absolute_percentage_error(y_val, y_val_pred)
    r2 = r2_score(y_val, y_val_pred)
    cv_rmse.append(rmse)
    cv_mae.append(mae)
    cv_mape.append(mape)
    cv_r2.append(r2)
    all_y_val.extend(y_val)
    all_y_val_pred.extend(y_val_pred)
# Prosječne metrike iz križne validacije
print(f"Prosječan MAPE (Križna validacija): {np.mean(cv_mape):.4f}")
print(f"Prosječan RMSE (Križna validacija): {np.mean(cv_rmse):.4f}")
print(f"Prosječan MAE (Križna validacija): {np.mean(cv_mae):.4f}")
print(f"Prosječan R2 (Križna validacija): {np.mean(cv_r2):.4f}")
# VIZUALIZACIJE
# Rezidualne greške
residuals_kfold = np.array(all_y_val) - np.array(all_y_val_pred)
# Histogram rezidualnih grešaka
plt.figure(figsize=(8, 6))
plt.hist(residuals_kfold, bins=30, edgecolor='k', alpha=0.7)
plt.axvline(0, color='red', linestyle='--', label='Idealno (Rezidual = 0)')
plt.title("Histogram rezidualnih grešaka (Križna validacija)")
plt.xlabel("Rezidualne greške")
plt.ylabel("Frekvencija")

```

```

plt.legend()
plt.show()
# Scatter plot stvarnih vrijednosti vs predviđanja
plt.figure(figsize=(8, 6))
plt.scatter(all_y_val, all_y_val_pred, alpha=0.5, label='Predviđanja')
plt.plot([min(all_y_val), max(all_y_val)], [min(all_y_val), max(all_y_val)],
         color='red', linestyle='--', label='Idealna linija')
plt.title("Stvarne vrijednosti vs predviđanja (Križna validacija)")
plt.xlabel("Stvarne vrijednosti")
plt.ylabel("Predviđanja")
plt.legend()
plt.show()
# Kumulativna distribucija apsolutnih grešaka
sorted_errors_kfold = np.sort(np.abs(residuals_kfold))
cumulative_kfold = np.arange(1, len(sorted_errors_kfold) + 1) /
len(sorted_errors_kfold)
plt.figure(figsize=(8, 6))
plt.plot(sorted_errors_kfold, cumulative_kfold, label="Kumulativna distribucija
grešaka")
plt.axvline(np.median(sorted_errors_kfold), color='red', linestyle='--', label='Medijan
greške')
plt.title("Kumulativna distribucija apsolutnih grešaka (Križna validacija)")
plt.xlabel("Apsolutna greška")
plt.ylabel("Kumulativni postotak")
plt.legend()
plt.show()
# Box plot stvarnih vrijednosti i predviđanja
plt.figure(figsize=(8, 6))
sns.boxplot(data=[all_y_val, all_y_val_pred], palette="Set2")
plt.xticks([0, 1], ["Stvarne vrijednosti", "Predviđanja"])
plt.title("Box plot stvarnih vrijednosti vs predviđanja (Križna validacija)")
plt.show()

```

Prilog D: Ulazni podatci modela predviđanja kumulativne krivulje napretka

Ugovoreni iznos	Realizirani iznos	Prekoračenje vremena	Prekoračenje iznosa	Segment vrijeme	Segment iznos	Tip: cestovna infrastruktura	Tip: komunalna infrastruktura	Tip: visokogradnja
0,42689	1,00000	1,00000	1,00000	0,03226	0,00763	0	0	1
0,42689	1,00000	1,00000	1,00000	0,06452	0,03670	0	0	1
0,42689	1,00000	1,00000	1,00000	0,09677	0,06362	0	0	1
0,42689	1,00000	1,00000	1,00000	0,12903	0,08346	0	0	1
0,42689	1,00000	1,00000	1,00000	0,16129	0,10700	0	0	1
0,42689	1,00000	1,00000	1,00000	0,19355	0,13479	0	0	1
0,42689	1,00000	1,00000	1,00000	0,22581	0,15700	0	0	1
0,42689	1,00000	1,00000	1,00000	0,25806	0,20198	0	0	1
0,42689	1,00000	1,00000	1,00000	0,29032	0,25493	0	0	1
0,42689	1,00000	1,00000	1,00000	0,32258	0,32188	0	0	1
0,42689	1,00000	1,00000	1,00000	0,35484	0,40460	0	0	1
0,42689	1,00000	1,00000	1,00000	0,38710	0,45458	0	0	1
0,42689	1,00000	1,00000	1,00000	0,41935	0,53569	0	0	1
0,42689	1,00000	1,00000	1,00000	0,45161	0,57682	0	0	1
0,42689	1,00000	1,00000	1,00000	0,48387	0,66426	0	0	1
0,42689	1,00000	1,00000	1,00000	0,51613	0,71561	0	0	1
0,42689	1,00000	1,00000	1,00000	0,54839	0,73883	0	0	1
0,42689	1,00000	1,00000	1,00000	0,58065	0,74973	0	0	1
0,42689	1,00000	1,00000	1,00000	0,61290	0,75897	0	0	1
0,42689	1,00000	1,00000	1,00000	0,64516	0,76336	0	0	1
0,42689	1,00000	1,00000	1,00000	0,67742	0,76895	0	0	1
0,42689	1,00000	1,00000	1,00000	0,70968	0,77476	0	0	1
0,42689	1,00000	1,00000	1,00000	0,74194	0,78987	0	0	1
0,42689	1,00000	1,00000	1,00000	0,77419	0,81495	0	0	1
0,42689	1,00000	1,00000	1,00000	0,80645	0,83919	0	0	1
0,42689	1,00000	1,00000	1,00000	0,83871	0,86725	0	0	1
0,42689	1,00000	1,00000	1,00000	0,87097	0,88913	0	0	1
0,42689	1,00000	1,00000	1,00000	0,90323	0,90641	0	0	1
0,42689	1,00000	1,00000	1,00000	0,93548	0,93174	0	0	1
0,42689	1,00000	1,00000	1,00000	0,96774	0,96668	0	0	1
0,42689	1,00000	1,00000	1,00000	1,00000	1,00000	0	0	1
0,82004	0,36405	0,00000	0,00000	0,03030	0,00163	0	0	1
0,82004	0,36405	0,00000	0,00000	0,06061	0,00759	0	0	1

0,82004	0,36405	0,00000	0,00000	0,09091	0,01840	0	0	1
0,82004	0,36405	0,00000	0,00000	0,12121	0,03206	0	0	1
0,82004	0,36405	0,00000	0,00000	0,15152	0,05834	0	0	1
0,82004	0,36405	0,00000	0,00000	0,18182	0,09593	0	0	1
0,82004	0,36405	0,00000	0,00000	0,21212	0,13376	0	0	1
0,82004	0,36405	0,00000	0,00000	0,24242	0,15921	0	0	1
0,82004	0,36405	0,00000	0,00000	0,27273	0,19151	0	0	1
0,82004	0,36405	0,00000	0,00000	0,30303	0,24772	0	0	1
0,82004	0,36405	0,00000	0,00000	0,33333	0,28454	0	0	1
0,82004	0,36405	0,00000	0,00000	0,36364	0,31982	0	0	1
0,82004	0,36405	0,00000	0,00000	0,39394	0,34897	0	0	1
0,82004	0,36405	0,00000	0,00000	0,42424	0,37726	0	0	1
0,82004	0,36405	0,00000	0,00000	0,45455	0,40555	0	0	1
0,82004	0,36405	0,00000	0,00000	0,48485	0,43006	0	0	1
0,82004	0,36405	0,00000	0,00000	0,51515	0,46146	0	0	1
0,82004	0,36405	0,00000	0,00000	0,54545	0,50829	0	0	1
0,82004	0,36405	0,00000	0,00000	0,57576	0,53583	0	0	1
0,82004	0,36405	0,00000	0,00000	0,60606	0,56733	0	0	1
0,82004	0,36405	0,00000	0,00000	0,63636	0,60129	0	0	1
0,82004	0,36405	0,00000	0,00000	0,66667	0,62572	0	0	1
0,82004	0,36405	0,00000	0,00000	0,69697	0,65106	0	0	1
0,82004	0,36405	0,00000	0,00000	0,72727	0,67455	0	0	1
0,82004	0,36405	0,00000	0,00000	0,75758	0,71157	0	0	1
0,82004	0,36405	0,00000	0,00000	0,78788	0,74405	0	0	1
0,82004	0,36405	0,00000	0,00000	0,81818	0,78660	0	0	1
0,82004	0,36405	0,00000	0,00000	0,84848	0,83236	0	0	1
0,82004	0,36405	0,00000	0,00000	0,87879	0,87376	0	0	1
0,82004	0,36405	0,00000	0,00000	0,90909	0,92503	0	0	1
0,82004	0,36405	0,00000	0,00000	0,93939	0,95709	0	0	1
0,82004	0,36405	0,00000	0,00000	0,96970	0,97418	0	0	1
0,82004	0,36405	0,00000	0,00000	1,00000	1,00000	0	0	1
1,00000	0,87961	0,41417	0,26059	0,04545	0,00521	0	0	1
1,00000	0,87961	0,41417	0,26059	0,09091	0,03427	0	0	1
1,00000	0,87961	0,41417	0,26059	0,13636	0,07374	0	0	1
1,00000	0,87961	0,41417	0,26059	0,18182	0,10730	0	0	1
1,00000	0,87961	0,41417	0,26059	0,22727	0,15089	0	0	1
1,00000	0,87961	0,41417	0,26059	0,27273	0,20887	0	0	1
1,00000	0,87961	0,41417	0,26059	0,31818	0,23471	0	0	1
1,00000	0,87961	0,41417	0,26059	0,36364	0,25969	0	0	1

1,00000	0,87961	0,41417	0,26059	0,40909	0,28660	0	0	1
1,00000	0,87961	0,41417	0,26059	0,45455	0,32860	0	0	1
1,00000	0,87961	0,41417	0,26059	0,50000	0,37013	0	0	1
1,00000	0,87961	0,41417	0,26059	0,54545	0,40838	0	0	1
1,00000	0,87961	0,41417	0,26059	0,59091	0,45762	0	0	1
1,00000	0,87961	0,41417	0,26059	0,63636	0,51812	0	0	1
1,00000	0,87961	0,41417	0,26059	0,68182	0,60062	0	0	1
1,00000	0,87961	0,41417	0,26059	0,72727	0,68562	0	0	1
1,00000	0,87961	0,41417	0,26059	0,77273	0,75543	0	0	1
1,00000	0,87961	0,41417	0,26059	0,81818	0,80791	0	0	1
1,00000	0,87961	0,41417	0,26059	0,86364	0,85635	0	0	1
1,00000	0,87961	0,41417	0,26059	0,90909	0,91238	0	0	1
1,00000	0,87961	0,41417	0,26059	0,95455	0,96838	0	0	1
1,00000	0,87961	0,41417	0,26059	1,00000	1,00000	0	0	1
0,11144	0,03441	0,33643	0,24063	0,03846	0,00308	0	1	0
0,11144	0,03441	0,33643	0,24063	0,07692	0,01376	0	1	0
0,11144	0,03441	0,33643	0,24063	0,11538	0,06039	0	1	0
0,11144	0,03441	0,33643	0,24063	0,15385	0,14162	0	1	0
0,11144	0,03441	0,33643	0,24063	0,19231	0,18896	0	1	0
0,11144	0,03441	0,33643	0,24063	0,23077	0,26093	0	1	0
0,11144	0,03441	0,33643	0,24063	0,26923	0,30131	0	1	0
0,11144	0,03441	0,33643	0,24063	0,30769	0,34963	0	1	0
0,11144	0,03441	0,33643	0,24063	0,34615	0,38939	0	1	0
0,11144	0,03441	0,33643	0,24063	0,38462	0,40837	0	1	0
0,11144	0,03441	0,33643	0,24063	0,42308	0,41530	0	1	0
0,11144	0,03441	0,33643	0,24063	0,46154	0,43648	0	1	0
0,11144	0,03441	0,33643	0,24063	0,50000	0,47539	0	1	0
0,11144	0,03441	0,33643	0,24063	0,53846	0,50228	0	1	0
0,11144	0,03441	0,33643	0,24063	0,57692	0,53363	0	1	0
0,11144	0,03441	0,33643	0,24063	0,61538	0,57819	0	1	0
0,11144	0,03441	0,33643	0,24063	0,65385	0,63931	0	1	0
0,11144	0,03441	0,33643	0,24063	0,69231	0,69069	0	1	0
0,11144	0,03441	0,33643	0,24063	0,73077	0,74155	0	1	0
0,11144	0,03441	0,33643	0,24063	0,76923	0,80448	0	1	0
0,11144	0,03441	0,33643	0,24063	0,80769	0,85235	0	1	0
0,11144	0,03441	0,33643	0,24063	0,84615	0,87878	0	1	0
0,11144	0,03441	0,33643	0,24063	0,88462	0,89784	0	1	0
0,11144	0,03441	0,33643	0,24063	0,92308	0,91682	0	1	0
0,11144	0,03441	0,33643	0,24063	0,96154	0,95609	0	1	0

0,11144	0,03441	0,33643	0,24063	1,00000	1,00000	0	1	0
0,62012	0,56589	0,42078	0,29947	0,02857	0,03304	0	1	0
0,62012	0,56589	0,42078	0,29947	0,05714	0,03406	0	1	0
0,62012	0,56589	0,42078	0,29947	0,08571	0,04940	0	1	0
0,62012	0,56589	0,42078	0,29947	0,11429	0,07651	0	1	0
0,62012	0,56589	0,42078	0,29947	0,14286	0,11680	0	1	0
0,62012	0,56589	0,42078	0,29947	0,17143	0,12008	0	1	0
0,62012	0,56589	0,42078	0,29947	0,20000	0,18673	0	1	0
0,62012	0,56589	0,42078	0,29947	0,22857	0,18679	0	1	0
0,62012	0,56589	0,42078	0,29947	0,25714	0,22853	0	1	0
0,62012	0,56589	0,42078	0,29947	0,28571	0,27832	0	1	0
0,62012	0,56589	0,42078	0,29947	0,31429	0,28614	0	1	0
0,62012	0,56589	0,42078	0,29947	0,34286	0,31103	0	1	0
0,62012	0,56589	0,42078	0,29947	0,37143	0,35528	0	1	0
0,62012	0,56589	0,42078	0,29947	0,40000	0,39554	0	1	0
0,62012	0,56589	0,42078	0,29947	0,42857	0,42649	0	1	0
0,62012	0,56589	0,42078	0,29947	0,45714	0,45685	0	1	0
0,62012	0,56589	0,42078	0,29947	0,48571	0,48454	0	1	0
0,62012	0,56589	0,42078	0,29947	0,51429	0,51525	0	1	0
0,62012	0,56589	0,42078	0,29947	0,54286	0,51655	0	1	0
0,62012	0,56589	0,42078	0,29947	0,57143	0,53922	0	1	0
0,62012	0,56589	0,42078	0,29947	0,60000	0,54672	0	1	0
0,62012	0,56589	0,42078	0,29947	0,62857	0,55405	0	1	0
0,62012	0,56589	0,42078	0,29947	0,65714	0,55546	0	1	0
0,62012	0,56589	0,42078	0,29947	0,68571	0,57209	0	1	0
0,62012	0,56589	0,42078	0,29947	0,71429	0,62108	0	1	0
0,62012	0,56589	0,42078	0,29947	0,74286	0,62507	0	1	0
0,62012	0,56589	0,42078	0,29947	0,77143	0,62602	0	1	0
0,62012	0,56589	0,42078	0,29947	0,80000	0,73657	0	1	0
0,62012	0,56589	0,42078	0,29947	0,82857	0,73735	0	1	0
0,62012	0,56589	0,42078	0,29947	0,85714	0,82131	0	1	0
0,62012	0,56589	0,42078	0,29947	0,88571	0,85406	0	1	0
0,62012	0,56589	0,42078	0,29947	0,91429	0,90196	0	1	0
0,62012	0,56589	0,42078	0,29947	0,94286	0,90930	0	1	0
0,62012	0,56589	0,42078	0,29947	0,97143	0,93240	0	1	0
0,62012	0,56589	0,42078	0,29947	1,00000	1,00000	0	1	0
0,00000	0,00000	0,31000	0,40437	0,03704	0,00567	1	0	0
0,00000	0,00000	0,31000	0,40437	0,07407	0,02382	1	0	0
0,00000	0,00000	0,31000	0,40437	0,11111	0,04697	1	0	0

0,00000	0,00000	0,31000	0,40437	0,14815	0,08797	1	0	0
0,00000	0,00000	0,31000	0,40437	0,18519	0,23336	1	0	0
0,00000	0,00000	0,31000	0,40437	0,22222	0,34172	1	0	0
0,00000	0,00000	0,31000	0,40437	0,25926	0,39142	1	0	0
0,00000	0,00000	0,31000	0,40437	0,29630	0,42500	1	0	0
0,00000	0,00000	0,31000	0,40437	0,33333	0,44031	1	0	0
0,00000	0,00000	0,31000	0,40437	0,37037	0,44379	1	0	0
0,00000	0,00000	0,31000	0,40437	0,40741	0,45975	1	0	0
0,00000	0,00000	0,31000	0,40437	0,44444	0,48338	1	0	0
0,00000	0,00000	0,31000	0,40437	0,48148	0,50118	1	0	0
0,00000	0,00000	0,31000	0,40437	0,51852	0,53256	1	0	0
0,00000	0,00000	0,31000	0,40437	0,55556	0,61544	1	0	0
0,00000	0,00000	0,31000	0,40437	0,59259	0,70992	1	0	0
0,00000	0,00000	0,31000	0,40437	0,62963	0,78191	1	0	0
0,00000	0,00000	0,31000	0,40437	0,66667	0,81823	1	0	0
0,00000	0,00000	0,31000	0,40437	0,70370	0,86246	1	0	0
0,00000	0,00000	0,31000	0,40437	0,74074	0,86894	1	0	0
0,00000	0,00000	0,31000	0,40437	0,77778	0,87343	1	0	0
0,00000	0,00000	0,31000	0,40437	0,81481	0,88000	1	0	0
0,00000	0,00000	0,31000	0,40437	0,85185	0,89319	1	0	0
0,00000	0,00000	0,31000	0,40437	0,88889	0,92151	1	0	0
0,00000	0,00000	0,31000	0,40437	0,92593	0,93436	1	0	0
0,00000	0,00000	0,31000	0,40437	0,96296	0,97221	1	0	0
0,00000	0,00000	0,31000	0,40437	1,00000	1,00000	1	0	0
0,65287	0,91209	0,26841	0,57416	0,03448	0,15415	1	0	0
0,65287	0,91209	0,26841	0,57416	0,06897	0,17761	1	0	0
0,65287	0,91209	0,26841	0,57416	0,10345	0,19854	1	0	0
0,65287	0,91209	0,26841	0,57416	0,13793	0,21198	1	0	0
0,65287	0,91209	0,26841	0,57416	0,17241	0,25752	1	0	0
0,65287	0,91209	0,26841	0,57416	0,20690	0,29301	1	0	0
0,65287	0,91209	0,26841	0,57416	0,24138	0,31392	1	0	0
0,65287	0,91209	0,26841	0,57416	0,27586	0,34018	1	0	0
0,65287	0,91209	0,26841	0,57416	0,31034	0,37642	1	0	0
0,65287	0,91209	0,26841	0,57416	0,34483	0,41063	1	0	0
0,65287	0,91209	0,26841	0,57416	0,37931	0,46660	1	0	0
0,65287	0,91209	0,26841	0,57416	0,41379	0,50747	1	0	0
0,65287	0,91209	0,26841	0,57416	0,44828	0,54216	1	0	0
0,65287	0,91209	0,26841	0,57416	0,48276	0,56749	1	0	0
0,65287	0,91209	0,26841	0,57416	0,51724	0,60116	1	0	0

0,65287	0,91209	0,26841	0,57416	0,55172	0,62935	1	0	0
0,65287	0,91209	0,26841	0,57416	0,58621	0,67470	1	0	0
0,65287	0,91209	0,26841	0,57416	0,62069	0,72304	1	0	0
0,65287	0,91209	0,26841	0,57416	0,65517	0,77541	1	0	0
0,65287	0,91209	0,26841	0,57416	0,68966	0,81048	1	0	0
0,65287	0,91209	0,26841	0,57416	0,72414	0,84636	1	0	0
0,65287	0,91209	0,26841	0,57416	0,75862	0,88469	1	0	0
0,65287	0,91209	0,26841	0,57416	0,79310	0,93804	1	0	0
0,65287	0,91209	0,26841	0,57416	0,82759	0,95638	1	0	0
0,65287	0,91209	0,26841	0,57416	0,86207	0,97323	1	0	0
0,65287	0,91209	0,26841	0,57416	0,89655	0,98735	1	0	0
0,65287	0,91209	0,26841	0,57416	0,93103	0,98750	1	0	0
0,65287	0,91209	0,26841	0,57416	0,96552	0,99252	1	0	0
0,65287	0,91209	0,26841	0,57416	1,00000	1,00000	1	0	0
0,42816	0,41564	0,62233	0,34246	0,02703	0,00119	1	0	0
0,42816	0,41564	0,62233	0,34246	0,05405	0,00300	1	0	0
0,42816	0,41564	0,62233	0,34246	0,08108	0,00581	1	0	0
0,42816	0,41564	0,62233	0,34246	0,10811	0,01036	1	0	0
0,42816	0,41564	0,62233	0,34246	0,13514	0,01422	1	0	0
0,42816	0,41564	0,62233	0,34246	0,16216	0,01676	1	0	0
0,42816	0,41564	0,62233	0,34246	0,18919	0,02808	1	0	0
0,42816	0,41564	0,62233	0,34246	0,21622	0,05149	1	0	0
0,42816	0,41564	0,62233	0,34246	0,24324	0,09028	1	0	0
0,42816	0,41564	0,62233	0,34246	0,27027	0,11708	1	0	0
0,42816	0,41564	0,62233	0,34246	0,29730	0,15681	1	0	0
0,42816	0,41564	0,62233	0,34246	0,32432	0,20930	1	0	0
0,42816	0,41564	0,62233	0,34246	0,35135	0,27507	1	0	0
0,42816	0,41564	0,62233	0,34246	0,37838	0,36447	1	0	0
0,42816	0,41564	0,62233	0,34246	0,40541	0,39622	1	0	0
0,42816	0,41564	0,62233	0,34246	0,43243	0,43479	1	0	0
0,42816	0,41564	0,62233	0,34246	0,45946	0,45973	1	0	0
0,42816	0,41564	0,62233	0,34246	0,48649	0,47875	1	0	0
0,42816	0,41564	0,62233	0,34246	0,51351	0,52223	1	0	0
0,42816	0,41564	0,62233	0,34246	0,54054	0,55577	1	0	0
0,42816	0,41564	0,62233	0,34246	0,56757	0,58191	1	0	0
0,42816	0,41564	0,62233	0,34246	0,59459	0,60330	1	0	0
0,42816	0,41564	0,62233	0,34246	0,62162	0,62231	1	0	0
0,42816	0,41564	0,62233	0,34246	0,64865	0,63393	1	0	0
0,42816	0,41564	0,62233	0,34246	0,67568	0,65758	1	0	0

0,42816	0,41564	0,62233	0,34246	0,70270	0,66519	1	0	0
0,42816	0,41564	0,62233	0,34246	0,72973	0,67220	1	0	0
0,42816	0,41564	0,62233	0,34246	0,75676	0,68952	1	0	0
0,42816	0,41564	0,62233	0,34246	0,78378	0,70220	1	0	0
0,42816	0,41564	0,62233	0,34246	0,81081	0,71600	1	0	0
0,42816	0,41564	0,62233	0,34246	0,83784	0,77080	1	0	0
0,42816	0,41564	0,62233	0,34246	0,86486	0,80232	1	0	0
0,42816	0,41564	0,62233	0,34246	0,89189	0,85879	1	0	0
0,42816	0,41564	0,62233	0,34246	0,91892	0,89063	1	0	0
0,42816	0,41564	0,62233	0,34246	0,94595	0,95115	1	0	0
0,42816	0,41564	0,62233	0,34246	0,97297	0,96105	1	0	0
0,42816	0,41564	0,62233	0,34246	1,00000	1,00000	1	0	0
0,12616	0,11780	0,41692	0,36662	0,03704	0,00035	1	0	0
0,12616	0,11780	0,41692	0,36662	0,07407	0,00283	1	0	0
0,12616	0,11780	0,41692	0,36662	0,11111	0,01007	1	0	0
0,12616	0,11780	0,41692	0,36662	0,14815	0,01797	1	0	0
0,12616	0,11780	0,41692	0,36662	0,18519	0,02549	1	0	0
0,12616	0,11780	0,41692	0,36662	0,22222	0,04437	1	0	0
0,12616	0,11780	0,41692	0,36662	0,25926	0,08858	1	0	0
0,12616	0,11780	0,41692	0,36662	0,29630	0,13642	1	0	0
0,12616	0,11780	0,41692	0,36662	0,33333	0,18676	1	0	0
0,12616	0,11780	0,41692	0,36662	0,37037	0,22912	1	0	0
0,12616	0,11780	0,41692	0,36662	0,40741	0,28440	1	0	0
0,12616	0,11780	0,41692	0,36662	0,44444	0,34252	1	0	0
0,12616	0,11780	0,41692	0,36662	0,48148	0,39954	1	0	0
0,12616	0,11780	0,41692	0,36662	0,51852	0,44244	1	0	0
0,12616	0,11780	0,41692	0,36662	0,55556	0,48386	1	0	0
0,12616	0,11780	0,41692	0,36662	0,59259	0,53688	1	0	0
0,12616	0,11780	0,41692	0,36662	0,62963	0,59107	1	0	0
0,12616	0,11780	0,41692	0,36662	0,66667	0,65782	1	0	0
0,12616	0,11780	0,41692	0,36662	0,70370	0,71860	1	0	0
0,12616	0,11780	0,41692	0,36662	0,74074	0,77737	1	0	0
0,12616	0,11780	0,41692	0,36662	0,77778	0,84051	1	0	0
0,12616	0,11780	0,41692	0,36662	0,81481	0,90565	1	0	0
0,12616	0,11780	0,41692	0,36662	0,85185	0,96573	1	0	0
0,12616	0,11780	0,41692	0,36662	0,88889	0,97981	1	0	0
0,12616	0,11780	0,41692	0,36662	0,92593	0,98915	1	0	0
0,12616	0,11780	0,41692	0,36662	0,96296	0,99119	1	0	0
0,12616	0,11780	0,41692	0,36662	1,00000	1,00000	1	0	0

0,10029	0,03393	0,49950	0,25916	0,03571	0,00256	0	0	1
0,10029	0,03393	0,49950	0,25916	0,07143	0,00378	0	0	1
0,10029	0,03393	0,49950	0,25916	0,10714	0,01266	0	0	1
0,10029	0,03393	0,49950	0,25916	0,14286	0,03631	0	0	1
0,10029	0,03393	0,49950	0,25916	0,17857	0,07357	0	0	1
0,10029	0,03393	0,49950	0,25916	0,21429	0,11000	0	0	1
0,10029	0,03393	0,49950	0,25916	0,25000	0,14973	0	0	1
0,10029	0,03393	0,49950	0,25916	0,28571	0,24019	0	0	1
0,10029	0,03393	0,49950	0,25916	0,32143	0,34536	0	0	1
0,10029	0,03393	0,49950	0,25916	0,35714	0,39511	0	0	1
0,10029	0,03393	0,49950	0,25916	0,39286	0,44207	0	0	1
0,10029	0,03393	0,49950	0,25916	0,42857	0,51870	0	0	1
0,10029	0,03393	0,49950	0,25916	0,46429	0,56714	0	0	1
0,10029	0,03393	0,49950	0,25916	0,50000	0,61849	0	0	1
0,10029	0,03393	0,49950	0,25916	0,53571	0,65908	0	0	1
0,10029	0,03393	0,49950	0,25916	0,57143	0,69187	0	0	1
0,10029	0,03393	0,49950	0,25916	0,60714	0,73089	0	0	1
0,10029	0,03393	0,49950	0,25916	0,64286	0,75092	0	0	1
0,10029	0,03393	0,49950	0,25916	0,67857	0,78417	0	0	1
0,10029	0,03393	0,49950	0,25916	0,71429	0,83342	0	0	1
0,10029	0,03393	0,49950	0,25916	0,75000	0,87482	0	0	1
0,10029	0,03393	0,49950	0,25916	0,78571	0,91835	0	0	1
0,10029	0,03393	0,49950	0,25916	0,82143	0,93762	0	0	1
0,10029	0,03393	0,49950	0,25916	0,85714	0,95442	0	0	1
0,10029	0,03393	0,49950	0,25916	0,89286	0,97201	0	0	1
0,10029	0,03393	0,49950	0,25916	0,92857	0,97260	0	0	1
0,10029	0,03393	0,49950	0,25916	0,96429	0,99851	0	0	1
0,10029	0,03393	0,49950	0,25916	1,00000	1,00000	0	0	1
0,01491	0,03649	0,73485	0,45104	0,04000	0,03103	1	0	0
0,01491	0,03649	0,73485	0,45104	0,08000	0,06818	1	0	0
0,01491	0,03649	0,73485	0,45104	0,12000	0,12066	1	0	0
0,01491	0,03649	0,73485	0,45104	0,16000	0,19095	1	0	0
0,01491	0,03649	0,73485	0,45104	0,20000	0,25240	1	0	0
0,01491	0,03649	0,73485	0,45104	0,24000	0,31112	1	0	0
0,01491	0,03649	0,73485	0,45104	0,28000	0,35105	1	0	0
0,01491	0,03649	0,73485	0,45104	0,32000	0,36961	1	0	0
0,01491	0,03649	0,73485	0,45104	0,36000	0,39873	1	0	0
0,01491	0,03649	0,73485	0,45104	0,40000	0,45815	1	0	0
0,01491	0,03649	0,73485	0,45104	0,44000	0,48524	1	0	0

0,01491	0,03649	0,73485	0,45104	0,48000	0,53974	1	0	0
0,01491	0,03649	0,73485	0,45104	0,52000	0,59521	1	0	0
0,01491	0,03649	0,73485	0,45104	0,56000	0,65533	1	0	0
0,01491	0,03649	0,73485	0,45104	0,60000	0,67888	1	0	0
0,01491	0,03649	0,73485	0,45104	0,64000	0,83309	1	0	0
0,01491	0,03649	0,73485	0,45104	0,72000	0,88022	1	0	0
0,01491	0,03649	0,73485	0,45104	0,76000	0,91416	1	0	0
0,01491	0,03649	0,73485	0,45104	0,80000	0,91435	1	0	0
0,01491	0,03649	0,73485	0,45104	0,84000	0,92991	1	0	0
0,01491	0,03649	0,73485	0,45104	0,88000	0,94371	1	0	0
0,01491	0,03649	0,73485	0,45104	0,92000	0,96602	1	0	0
0,01491	0,03649	0,73485	0,45104	0,96000	0,98332	1	0	0
0,01491	0,03649	0,73485	0,45104	1,00000	1,00000	1	0	0

POPIS SLIKA

Slika 1. Definiranje upita putem Vennovog dijagrama.....	11
Slika 2. Dekompozicija upita za pretraživanje	11
Slika 3. Trend objavljivanja publikacija prema postavljenom upitu	12
Slika 4. Ključne riječi grupirane u klastere.....	14
Slika 5. Vizualizacija ključnih riječi (razvoj kroz godine)	16
Slika 6. Mitchellov model za identifikaciju dionika (prema Mitchell i dr., 1997)	22
Slika 7. Hijerarhija odlučivanja (oblikovao autor prema Jajac, 2010 i Marović, 2013).....	37
Slika 8. Odnos između umjetne inteligencije, strojnog učenja i dubokog učenja (Kelleher, 2019)	41
Slika 9. Tipična arhitektura neuronske mreže (Kim i dr., 2004)	44
Slika 10. Metodologija istraživanja.....	51
Slika 11. Proces razvoja evaluacijskog okvira za predviđanje performansi i ishoda građevinskih projekata	53
Slika 12. Razvoj hijerarhijske struktura ciljeva za praćenje i evaluaciju uspješnosti projekta	54
Slika 13. Protokol višestruke studije slučaja.....	56
Slika 14. Proces razvoja modela predviđanja prekoračenja ugovorenog trajanja i iznosa	59
Slika 15. Proces razvoja i odabira modela predviđanja krivulje kumulativnog napretka projekta	71
Slika 16. Proces primjene modela i adaptivni ciklus	77
Slika 17. Gubitak kroz epohe za neuronsku mrežu s 9 značajki (model predviđanja prekoračenja ugovorenog trajanja).....	92
Slika 18. Gubitak kroz epohe za neuronsku mrežu s 10 značajki (model predviđanja prekoračenja ugovorenog trajanja)	92
Slika 19. Usporedba stvarnih i predviđenih vrijednosti nakon optimizacije (model predviđanja prekoračenja ugovorenog trajanja)	94
Slika 20. Relativna važnost pojedinih značajki u modelu predviđanja prekoračenja ugovorenog trajanja	94
Slika 21. Distribucija ciljne varijable (model predviđanja prekoračenja ugovorenog trajanja) ..	96
Slika 22. Gubitak modela predviđanja prekoračenja ugovorenog trajanja kroz epohe (nakon dodatne optimizacije)	96
Slika 23. Usporedba stvarnih i predviđenih vrijednosti nakon dodatne optimizacije (model predviđanja prekoračenja ugovorenog trajanja)	97
Slika 24. Dijagram raspršenja stvarnih i predviđenih vrijednosti (model predviđanja prekoračenja ugovorenog trajanja)	99
Slika 25. Rezidualne vrijednosti modela predviđanja prekoračenja ugovorenog trajanja	99
Slika 26. Kutijasti dijagram grešaka predviđanja (model predviđanja prekoračenja ugovorenog trajanja)	100
Slika 27. Gubitak kroz epohe za neuronsku mrežu s 3 značajke (model predviđanja prekoračenja ugovorenog iznosa).....	104
Slika 28. Gubitak kroz epohe za neuronsku mrežu sa 7 značajki (model predviđanja prekoračenja ugovorenog iznosa).....	105

Slika 29. Usporedba stvarnih i predviđenih vrijednosti nakon optimizacije (model predviđanja prekoračenja ugovorenog iznosa)	106
Slika 30. Relativna važnost pojedinih značajki u modelu predviđanja prekoračenja ugovorenog iznosa	106
Slika 31. Distribucija ciljne varijable prije i poslije SMOGN	108
Slika 32. Gubitak modela predviđanja prekoračenja ugovorenog iznosa (nakon dodatne optimizacije)	109
Slika 33. Usporedba stvarnih i predviđenih vrijednosti nakon dodatne optimizacije (model predviđanja prekoračenja ugovorenog iznosa)	110
Slika 34. Dijagram raspršenja stvarnih i predviđenih vrijednosti (model predviđanja prekoračenja ugovorenog iznosa)	110
Slika 35. Reziduali modela (model predviđanja prekoračenja ugovorenog iznosa)	111
Slika 36. Kutijasti dijagram grešaka predviđanja (model predviđanja prekoračenja ugovorenog iznosa)	112
Slika 37. Krivulje kumulativnog napretka najboljih matematičkih modela (cjelokupna baza podataka)	116
Slika 38. Dijagram raspršenja stvarnih i predviđenih vrijednosti: a) vrijednost projekta manja od 10 milijuna eura; b) vrijednost projekta veća od 10 milijuna eura	118
Slika 39. Rezidualni grafovi: a) vrijednost projekta manja od 10 milijuna eura; b) vrijednost projekta veća od 10 milijuna eura	118
Slika 40. Distribucija grešaka: a) vrijednost projekta manja od 10 milijuna eura; b) vrijednost projekta veća od 10 milijuna eura	119
Slika 41. Gubitak tijekom treniranja i validacije	121
Slika 42. Dijagram raspršenja stvarnih i predviđenih vrijednosti	121
Slika 43. Rezidualne vrijednosti modela predviđanja krivulje kumulativnog napretka	122
Slika 44. Histogram reziduala	122
Slika 45. Kutijasti dijagram stvarnih i predviđenih vrijednosti	123
Slika 46. Histogram rezidualnih grešaka (unakrsna validacija)	125
Slika 47. Dijagram raspršenja stvarnih i predviđenih vrijednosti (unakrsna validacija)	125
Slika 48. Dijagram raspršenja reziduala (unakrsna validacija)	126
Slika 49. Kutijasti dijagram stvarnih i predviđenih vrijednosti (unakrsna validacija)	127
Slika 50. Krivulja kumulativnog napretka aktivnog građevinskog projekta	132
Slika 51. Zemlje sličnih gospodarskih trendova u građevinskoj industriji	139

POPIS TABLICA

Tablica 1. Ključne riječi po učestalosti.....	13
Tablica 2. Definiranje dionika	21
Tablica 3. Objašnjenje razreda dionika (prema Mitchell i dr., 1997)	22
Tablica 4. Pregled ključnih područja izvedbe za procjenu uspjeha projekta (Galjanić i dr., 2023)	27
Tablica 5. Predloženi pokazatelji kvalitete i načini izračuna	29
Tablica 6. Predloženi pokazatelji vremena i načini izračuna	30
Tablica 7. Predloženi pokazatelji troškova i načini izračuna	31
Tablica 8. Predloženi pokazatelji sigurnosti i načini izračuna	32
Tablica 9. Predloženi pokazatelji profitabilnosti i načini izračuna	32
Tablica 10. Predloženi pokazatelji produktivnosti i načini izračuna.....	33
Tablica 11. Predloženi pokazatelji zadovoljstva sudionika i načini izračuna	34
Tablica 12. Predloženi pokazatelji zadovoljstva investitora i načini izračuna	35
Tablica 13. Struktura podataka korištenih u istraživanju.....	62
Tablica 14. Kriteriji uspjeha građevinskih projekata	63
Tablica 15. Sudionici uključeni u višestruke studije slučaja	84
Tablica 16. Pregled slučajeva vezanih uz prekoračenja ugovorenog trajanja i iznosa	84
Tablica 17. Rangiranje ključnih područja performansi temeljem procjene dionika	85
Tablica 18. Usporedba prekoračenja ugovorenog trajanja i iznosa s percepcijom dionika o ključnim područjima performansi	86
Tablica 19. Pregled optimalnih kombinacija broja značajki i arhitekture mreže s pripadajućim performansama (model predviđanja prekoračenja ugovorenog trajanja)	91
Tablica 20. Usporedba performansi modela neuronske mreže s 9 i 10 značajki (model predviđanja prekoračenja trajanja).....	93
Tablica 21. Usporedba performansi na skupu za treniranje i testiranje (model predviđanja prekoračenja ugovorenog trajanja)	97
Tablica 22. Usporedba stvarnih vrijednosti i predviđenih vrijednosti (model predviđanja prekoračenja ugovorenog trajanja)	98
Tablica 23. Statistički pokazatelji distribucije (model predviđanja prekoračenja ugovorenog trajanja)	100
Tablica 24. Rezultati metrika unakrsne validacije (3 skupa modela predviđanja prekoračenja ugovorenog trajanja).....	101
Tablica 25. Pregled optimalnih kombinacija broja značajki i arhitekture mreže s pripadajućim performansama (model predviđanja prekoračenja ugovorenog iznosa)	103
Tablica 26. Usporedba performansi modela neuronske mreže s 3 i 7 značajki (model predviđanja prekoračenja iznosa)	105
Tablica 27. Usporedba performansi na skupu za treniranje i testiranje (model predviđanja prekoračenja ugovorenog iznosa).....	108
Tablica 28. Usporedba stvarnih vrijednosti i predviđenih vrijednosti (model predviđanja prekoračenja ugovorenog iznosa).....	109
Tablica 29. Statistički pokazatelji (model predviđanja prekoračenja ugovorenog iznosa)	112

Tablica 30. Rezultati metrika unakrsne validacije (3 skupa modela predviđanja prekoračenja ugovorenog iznosa)	113
Tablica 31. Pregled performansi matematičkih modela prema kategorijama.....	117
Tablica 32. Usporedba performansi na skupu za treniranje, validaciju i testiranje (model predviđanja krivulje kumulativnog napretka)	120
Tablica 33. Statistički pokazatelji (model predviđanja krivulje kumulativnog napretka)	123
Tablica 34. Rezultati metrika unakrsne validacije (5 skupova modela predviđanja krivulje kumulativnog napretka)	124
Tablica 35. Statistički pokazatelji (unakrsna validacija, model predviđanja krivulje kumulativnog napretka)	126
Tablica 36. Usporedba performansi najboljih matematičkih modela i modela neuronske mreže u predviđanju krivulje kumulativnog napretka	128
Tablica 37. Najvažnije značajke modela predviđanja prekoračenja ugovorenog trajanja i ugovorenog iznosa	130
Tablica 38. Ulazni podatci o aktualnom projektu.....	131
Tablica 39. Ograničenja značajki aktivnog građevinskog projekta.....	133
Tablica 40. Kombinacije značajki koje daju predviđanje prekoračenja ugovorenog trajanja 0 %	133
Tablica 41. Pojavljivanja zemalja u klasteru s Hrvatskom	137
Tablica 42. Zemlje s visokom korelacijom s Hrvatskom	138

POPIS KRATICA

IPMA	Međunarodna udruga za upravljanje projektima
IQR	Interkvartilni raspon
ISO	Međunarodna organizacija za standardizaciju
KPI	Ključni pokazatelj uspješnosti
MAE	Srednja apsolutna greška
MSE	Srednja kvadratna greška
NN	Neuronske mreže
PCA	Analiza glavnih komponenata
PMBOK	Zbirka znanja o upravljanju projektima (engl. Project Management Body of Knowledge)
PMI	Institut za upravljanje projektima
R2	Koeficijent determinacije
ReLU	Rektificirana linearna jedinica (engl. Rectified Linear Unit)
RF	Algoritam slučajne šume
RMSE	Korijen srednje kvadratne greške
SGD	Stohastički gradijentni spust
SMAPE	Simetrična srednja apsolutna postotna greška
SMART	Specifičan, mjerljiv, ostvariv, relevantan, vremenski ograničen
SOT	Sustav za obradu transakcija
SPI	Sustav za potporu izvršnim menadžerima
SPO	Sustav za podršku odlučivanju
UIS	Upravljački informacijski sustav
WBS	Struktura razrade zadataka

ŽIVOTOPIS AUTORA

Kristina Galjanić rođena je 18. prosinca 1992. godine u Rijeci. Završila je opću gimnaziju u Srednjoj školi Hrvatski kralj Zvonimir u Krku 2011. godine. Iste godine upisala je preddiplomski studij na Građevinskom fakultetu Sveučilišta u Rijeci, gdje je kasnije završila i diplomski studij (smjer Konstrukcije-Geotehnika). Tijekom studija radila je kao demonstratorica na kolegijima Linearna algebra, Mehanika tla i stijena te Osnove betonskih konstrukcija. Sudjelovala je na međunarodnom projektu Project Energy Future Tour u organizaciji The Lower Austrian Energy and Environment Agency (eNu). Završni semestar studija provela je u okviru Erasmus programa na Sveučilištu za prirodne resurse i znanosti o životu (BOKU) u Beču, gdje je izradila diplomski rad pod naslovom Numerical analysis of landslide at Grohovo, Croatia, pod mentorstvom prof. dr. sc. Wei Wua (BOKU) i komentorstvom prof. dr. sc. Željka Arbanasa (GF Rijeka). Diplomirala je 2016. godine. Od listopada 2016. do svibnja 2025. bila je zaposlena u tvrtki GP KRK d.d., najprije kao voditeljica radova, a potom kao inženjerka i glavna inženjerka gradilišta. U siječnju 2019. položila je stručni ispit za obavljanje poslova prostornog uređenja i graditeljstva. Sudjelovala je u provedbi građevinskih projekata sufinanciranih sredstvima Europske unije, uključujući rekonstrukciju sustava vodoopskrbe i rehabilitaciju sustava odvodnje otoka Krka te izgradnju dionice DC403, kao i u nizu manjih infrastrukturnih projekata. U ožujku 2020. godine upisala je poslijediplomski studij Građevinarstvo na Građevinskom fakultetu Sveučilišta u Rijeci. Tijekom studija pohađala je stručne i istraživačke radionice te napredne tečajeve programiranja, a dio istraživačkog rada provela je na Fakultetu građevinarstva Tehničkog sveučilišta u Brnu (VUT) te na Fakultetu za graditeljstvo, prometno inženjerstvo i arhitekturu Sveučilišta u Mariboru (FGPA). Bila je uključena u rad Građevinskog fakulteta Sveučilišta u Rijeci kao članica Odbora za unapređenje i kvalitetu te različitih stručnih radnih skupina. Autorica je više znanstvenih radova objavljenih u međunarodnim časopisima, a rezultate istraživanja predstavila na domaćim i međunarodnim konferencijama. Dobitnica je drugog mjesta IPMA nagrade u Hrvatskoj za najbolje znanstveno istraživanje u području upravljanja projektima. Sudjelovala je u znanstvenom projektu Koncept za podršku odlučivanju pri održivom upravljanju urbanih sredina, te je trenutno uključena u projekt Razvoj modela za upravljanje performansama građevinskih projekata temeljenog na metodama mekog računarstva, oba pod vodstvom prof. dr. sc. Ivana Marovića, u svojstvu suradnice doktorandice. Od svibnja 2025. godine zaposlena je kao asistentica na Građevinskom fakultetu Sveučilišta u Rijeci, na Katedri za organizaciju i tehnologiju građenja. Njezin istraživački interes usmjeren je na prijenos znanstvenih spoznaja u građevinsku praksu, osobito u području dinamičkog upravljanja projektima i primjene naprednih računalnih metoda u svakodnevnoj inženjerskoj praksi.