

Sveučilište Josipa Jurja Strossmayera u Osijeku
Građevinski i arhitektonski fakultet Osijek

Poslijediplomski sveučilišni studij Građevinarstvo

Doktorski rad

Razvoj sustava procjene stanja školskih zgrada i
modela procjene potrošnje energije, energenata i
vode

Hana Begić Juričić, mag.ing.aedif.

Osijek, veljača 2025. godine

Josip Juraj Strossmayer University of Osijek
Faculty of Civil Engineering and Architecture Osijek

Postgraduate University Study Programme in Civil Engineering

Development of a System for Assessing the Condition of School
Buildings and Models for Assessing Energy, Energy Sources and
Water Consumption

Hana Begić Juričić, M. Sc. in Civ. Eng.

Osijek, February 2025

Prosudbena povjerenstva i bibliografski podaci

Povjerenstvo za prihvaćanje teme doktorskog rada

Povjerenstvo za prihvaćanje teme doktorskog rada imenovano na 2. redovitoj sjednici Fakultetskog vijeća Građevinskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku, održanoj 13. studenog 2024. godine:

1. *prof. dr. sc. Zlata Dolaček-Alduk, redovita profesorica, Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek, predsjednica Povjerenstva*
2. *izv. prof. dr. sc. Ivana Miličević, izvanredna profesorica, Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek, članica*
3. *izv. prof. dr. sc. Katarina Rogulj, izvanredna profesorica, Sveučilište u Splitu, Fakultet građevinarstva, arhitekture i geodezije u Splitu, članica*

Tema i mentor doktorskog rada prihvaćeni su odlukom Fakultetskog vijeća Građevinskog i arhitektonskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku na 4. redovitoj sjednici održanoj 22. siječnja 2025. godine.

Povjerenstvo za ocjenu doktorskog rada

Povjerenstvo za obranu doktorskog rada

Doktorska disertacija sadržava 149 stranica, 22 ilustracije, 62 tablice i 289 citiranih publikacija.

Mentor doktorskog rada je prof. dr. sc. Hrvoje Krstić, dipl. ing. građ., Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek.

Istraživanje u okviru doktorskog rada pripada znanstvenom području tehničkih znanosti, znanstvenom polju temeljne tehničke znanosti.

Izjava o akademskoj čestitosti

Izjavljujem i svojim potpisom potvrđujem kako je doktorski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija. Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, odnosno prepisan iz necitiranog rada te kako nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem kako nisam prijavila doktorski rad s istovjetnom temom na drugom studiju Sveučilišta ili na drugom sveučilištu.

Osijek, 26. veljače 2025.

A handwritten signature in black ink, reading "Hana Begić Juričić", written over a horizontal line.

Hana Begić Juričić, mag. ing. aedif.

Predgovor

Zgrade predstavljaju značajan udio u ukupnoj potrošnji energije, a među njima su i obrazovne ustanove, čiji troškovi energije prema literaturi čine drugi najveći izdatak nakon plaća djelatnika. Unatoč tome, postoji nedostatak istraživanja o procjeni potrošnje energije školskih zgrada u Republici Hrvatskoj, dok je pitanje procjene potrošnje vode školskih zgrada globalno slabo istraženo. Također, istraživanja koja analiziraju energetske i obrazovne zgrade u Hrvatskoj su rijetka. Dodatni problem predstavlja ubrzano propadanje školskih zgrada uslijed nepravilne upotrebe i nedostatka održavanja, unatoč njihovom kulturnom i povijesnom značaju. Područje istraživanja obuhvaća analizu potrošnje električne i toplinske energije te vode u školskim zgradama, s naglaskom na razlike između stvarne i proračunske potrošnje, kao i razvoj modela za procjenu potrošnje energije i vode te sustava za ocjenu stanja. Opseg istraživanja uključuje osnovne i srednje škole iz Osječko-baranjske županije, pri čemu su razvijeni modeli validirani na vanjskom uzorku. U istraživanju su korišteni podaci iz Informacijskog sustava za gospodarenje energijom i energetske certifikate, a analize su provedene primjenom tradicionalnih i naprednih statističkih metoda. Rezultati istraživanja pružaju smjernice za daljnja istraživanja i praktične preporuke za upravljanje školskim zgradama.

Zahvaljujem Informacijskom sustavu za gospodarenje energijom (ISGE) i Ministarstvu prostornog uređenja, graditeljstva i državne imovine (MGIPU) na ustupljanju podataka za izradu doktorskog rada.

Veliko hvala mom mentoru prof. dr. sc. Hrvoju Krstiću za svu pomoć pri izradi doktorskog rada, ohrabivanje i za sva znanja koja mi je prenio. Također, hvala mu što me kroz mentorstvo na završnom, diplomskom, a sada i doktorskome radu ispratio kroz cijelo moje fakultetsko obrazovanje.

Hvala svim mojim prijateljima na riječima podrške i ohrabrenja.

Najveće hvala mojim roditeljima i mome mužu na podršci, strpljenju i vjerovanju u mene.

SAŽETAK

Zgrade čine više od 40 % potrošnje energije u mnogim zemljama svijeta, a među njima je i Republika Hrvatska. Obrazovne zgrade imaju velik udio u potrošnji energije te nakon plaća djelatnika, troškovi energije predstavljaju drugi najveći izdatak škole. Pregledom literature uočen je nedostatak istraživanja na temu procjene potrošnje energije školskih zgrada u Republici Hrvatskoj dok je nedostatak istraživanja na temu procjene potrošnje vode školskih zgrada utvrđen diljem svijeta. Osim toga, istraživanja koja su se bavila razlikom između proračunske i stvarne potrošnje energije školskih zgrada odnosno energetskim jazom također su nedostajuća u Hrvatskoj. Nadalje, uočeno je da velik broj zgrada brzo propada radi starenja i preopterećenja, unatoč tome što imaju kulturni i povijesni značaj, a među njima su i školske zgrade. Preopterećenje u ovom kontekstu odnosi se na stanje kada zgrada, zbog povećanog broja korisnika, nepravilne upotrebe ili nedostatka održavanja, doživljava veće opterećenje od onog na koje je bila projektirana. Pregledom literature uočeno je da je velik broj istraživanja proveden je s ciljem pronalaženja odgovarajućih standarda za ocjenjivanje, no također je primijećen nedostatak takvih istraživanja u Hrvatskoj. U doktorskom radu razvijeni su modeli procjene potrošnje električne energije, toplinske energije te mjesečne i godišnje potrošnje vode školskih zgrada koristeći uzorak osnovnih i srednjih škola iz Osječko-baranjske županije. Nadalje, utvrđena je i razlika između stvarne i proračunske potrošnje energije školskih zgrada u Osječko-baranjskoj županiji te uzroci i razlike. Osim toga, uspostavljen je i sustav procjene stanja također koristeći uzorak škola iz Osječko-baranjske županije koji omogućuje ocjenu stanja zgrade na razini elementa te ukupnu ocjenu na razini cijele zgrade. Podaci korišteni za analize, za razvoj modela i za uspostavljanje sustava preuzeti su iz Informacijskog sustava za gospodarenje energijom (ISGE) te iz energetskih certifikata predmetnih zgrada. Za razvoj modela i sustava korištene su tradicionalne metode kao što je višestruka linearna regresija i napredne metode kao što su umjetne neuronske mreže te algoritam nasumične šume. Prednost svih razvijenih modela i sustava je što se temelji na malom broju neovisnih varijabli koje su jednostavno mjerljive i relativno lako dostupne korisnicima. Provedena je i validacija razvijenih modela procjene potrošnje i sustava procjene stanja na posebnom uzorku za validaciju za koju je korišten uzorak škola izvan Osječko-baranjske županije. Korišteno je ukupno 40 škola pri čemu je 20 iz kontinentalne Hrvatske, a 20 iz primorske kako bi se utvrdilo jesu li razvijeni modeli i sustav primjenjivi i izvan granica županije. Na temelju prikazanih rezultata i analize predložene su smjernice za daljnja istraživanja te praktične smjernice za upravljanje imovinom u smislu energetske učinkovitosti i održivosti školskih zgrada.

Ključne riječi: školske zgrade, modeli procjene potrošnje energije, regresijski modeli, neuronske mreže, algoritam nasumične šume, procjena stanja zgrade, energetski jaz

ABSTRACT

Buildings account for more than 40% of energy consumption in many countries worldwide, including the Republic of Croatia. Educational buildings represent a significant share of energy consumption, and after employee salaries, energy costs are the second-largest expense for schools. A review of the literature revealed a lack of research on the topic of energy consumption prediction in school buildings in the Republic of Croatia, while the lack of research on water consumption prediction in school buildings has been identified globally. Furthermore, studies addressing the discrepancy between projected and actual energy consumption in school buildings, also known as the energy performance gap, are similarly scarce in Croatia. Additionally, it has been observed that a large number of buildings, including school buildings, deteriorate rapidly due to aging and overuse, despite their cultural and historical significance. Overuse in this context refers to the condition when a building, due to an increased number of users, improper use or lack of maintenance, experiences a higher load than that for which it was designed. A review of the literature found that numerous studies have been conducted to establish appropriate standards for evaluation, but a lack of such research has also been noted in Croatia. In the doctoral dissertation, models were developed to predict electricity consumption, thermal energy consumption, and monthly and annual water consumption in school buildings using a sample of primary and secondary schools from Osijek-Baranja County. Furthermore, the difference between actual and calculated energy consumption in school buildings in Osijek-Baranja County, along with the causes of these differences, was identified. In addition, a school building condition assessment system was established using the same sample of schools from Osijek-Baranja County, enabling the evaluation of the building's condition at the element level and providing an overall assessment at the level of the entire building. The data used for the analyses, model development, and system establishment were sourced from the Energy Management Information System (EMIS) and the energy certificates of the respective buildings. Traditional methods, such as multiple linear regression, and advanced methods, such as artificial neural networks and the random forest algorithm, were used to develop the models and system. The advantage of all the developed models and systems is that they are based on a small number of independent variables that are easy to measure and relatively accessible. Validation of the developed consumption estimation models and condition assessment systems was also conducted using a separate validation sample, consisting of schools outside Osijek-Baranja County. A total of 40 schools were used, with 20 from continental Croatia and 20 from the coastal region, to determine whether the developed models and systems are applicable beyond the boundaries of the county. Based on the presented results and analysis, guidelines for further research and practical recommendations

Begić Juričić, Hana, 2025, *Razvoj sustava procjene stanja školskih zgrada i modela procjene potrošnje energije, energenata i vode*. Doktorska disertacija. Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek.

for asset management in terms of energy efficiency and sustainability of school buildings were proposed.

Keywords: school buildings, energy consumption prediction models, regression models, neural networks, random forest algorithm, building condition assessment, energy performance gap

SADRŽAJ

SAŽETAK.....	I
ABSTRACT	II
POPIS SLIKA.....	VIII
POPIS TABLICA	IX
POPIS KRATICA I SIMBOLA	XII
1. UVOD	1
1.1. Predmet i problem istraživanja	1
1.2. Ciljevi i hipoteze istraživanja	3
1.3. Metode istraživanja	3
1.4. Struktura doktorskog rada i očekivani znanstveni doprinos	4
2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA O PROCJENI STANJA ZGRADA	7
2.1. Definicija procjene stanja zgrada	7
2.2. Hijerarhija pri procjeni stanja zgrada	11
2.3. Ljestvice ocjenjivanja stanja zgrada i lingvistički prikazi	14
2.4. Prethodna istraživanja o procjeni stanja zgrada	16
2.5. Prethodna istraživanja o procjeni stanja obrazovnih zgrada.....	23
3. PREGLED PRETHODNIH ISTRAŽIVANJA O ANALIZI I PROCJENI POTROŠNJE ENERGIJE, ENERGENATA I VODE U OBRAZOVNIM ZGRADAMA.....	32
3.1. Potrošnja energije, energenata i vode u obrazovnim zgradama.....	32
3.2. Prethodna istraživanja o analizi potrošnje energije, energenata i vode u obrazovnim zgradama	33
3.2.1. Prethodna istraživanja o analizi potrošnje električne i toplinske energije u obrazovnim zgradama.....	33
3.2.2. Prethodna istraživanja o analizi potrošnje vode u obrazovnim zgradama	37
3.3. Prethodna istraživanja o procjeni potrošnje energije, energenata i vode u obrazovnim zgradama	39

3.3.1.	Prethodna istraživanja o procjeni potrošnje električne i toplinske energije u obrazovnim zgradama.....	39
3.3.2.	Prethodna istraživanja o procjeni potrošnje vode u obrazovnim zgradama.....	43
3.4.	Razlika između stvarne i proračunske potrošnje energije u zgradama	44
3.4.1.	Definicija energetskog jaza	44
3.4.2.	Pregled prethodnih istraživanja o analizi razlike između stvarne i proračunske potrošnje energije u zgradama	45
3.4.3.	Pregled prethodnih istraživanja o analizi razlike između stvarne i proračunske potrošnje energije u obrazovnim zgradama.....	46
4.	PRIKUPLJANJE PODATAKA.....	48
4.1.	Pregled stanja i zakonodavnog okvira u Republici Hrvatskoj	48
4.2.	Podaci o javnim zgradama za obrazovanje u Republici Hrvatskoj.....	51
4.3.	Prikupljanje podataka o geometrijskim, materijalnim i uporabnim karakteristikama školskih zgrada te o njihovoj potrošnji energije, energenata i vode	56
5.	RAZVOJ MODELA ZA PROCJENU POTROŠNJE ENERGIJE, ENERGENATA I VODE I USPOREDBA STVARNE I PRORAČUNSKE POTROŠNJE ENERGIJE	63
5.1.	Razvoj modela za procjenu potrošnje električne energije	63
5.1.1.	Prikupljanje i analiza podataka za razvoj modela procjene potrošnje električne energije .	63
5.1.2.	Razvoj modela procjene potrošnje električne energije pomoću višestruke linearne regresije	67
5.1.3.	Razvoj modela procjene potrošnje električne energije pomoću neuronske mreže.....	68
5.1.4.	Usporedba točnosti razvijenih modela procjene potrošnje električne energije	70
5.1.5.	Zaključak	72
5.2.	Razvoj modela procjene potrošnje vode.....	73
5.2.2.	Razvijeni modeli procjene potrošnje vode pomoću višestruke linearne regresije	80
5.2.3.	Razvijeni modeli procjene potrošnje vode pomoću umjetnih neuronskih mreža.....	80
5.2.4.	Usporedba točnosti razvijenih modela procjene potrošnje vode	82
5.2.5.	Zaključak	85
5.3.	Razvoj modela procjene potrošnje toplinske energije	86

5.3.1.	Prikupljanje i analiza podataka za razvoj modela procjene potrošnje toplinske energije ..	86
5.3.2.	Razvijeni model procjene potrošnje toplinske energije pomoću višestruke linearne regresije	89
5.3.3.	Razvijeni model procjene godišnje potrošnje toplinske energije pomoću umjetne neuronske mreže	89
5.3.4.	Razvijeni model procjene godišnje potrošnje toplinske energije pomoću algoritma nasumične šume	90
5.3.5.	Usporedba točnosti razvijenih modela procjene potrošnje toplinske energije.....	91
5.3.6.	Zaključak	94
5.4.	Usporedba stvarne i proračunske potrošnje toplinske energije	95
5.4.1.	Prikupljanje i analiza podataka za usporedbu stvarne i proračunske potrošnje toplinske energije	95
5.4.2.	Analiza energetskega jaza.....	99
5.4.3.	Analiza uzroka pojave energetskega jaza.....	102
5.4.4.	Zaključak	105
6.	RAZVOJ SUSTAVA PROCJENE STANJA ŠKOLSKIH ZGRADA	106
6.1.	Prikupljanje i analiza podataka za razvoj sustava procjene stanja školskih zgrada	106
6.2.	Procjena stanja na razini elemenata	110
6.3.	Varijable za razvoj modela procjene stanja školskih zgrada.....	111
6.4.	Razvijeni model procjene stanja školskih zgrada pomoću umjetne neuronske mreže	113
6.5.	Razvijeni model procjene stanja školskih zgrada pomoću algoritma nasumične šume	115
6.6.	Usporedba točnosti razvijenih modela procjene stanja školskih zgrada	115
6.7.	Zaključak	116
7.	VALIDACIJA RAZVIJENIH MODELA PROCJENE POTROŠNJE ENERGIJE, ENERGENATA I VODE I SUSTAVA PROCJENE STANJA ŠKOLSKIH ZGRADA	118
7.1.	Uzorak za validaciju.....	118
7.2.	Validacija razvijenih modela procjene potrošnje električne energije.....	120
7.3.	Validacija razvijenih modela procjene potrošnje vode	121
7.4.	Validacija razvijenih modela procjene potrošnje toplinske energije	122

7.5.	Validacija razvijenog sustava procjene stanja	125
7.6.	Zaključak	126
8.	ZAKLJUČAK, PRAKTIČNE SMJERNICE ZA UPRAVLJANJE IMOVINOM U SMISLU ENERGETSKE UČINKOVITOSTI I ODRŽIVOSTI ŠKOLSKIH ZGRADA I SMJERNICE ZA DALJNJA ISTRAŽIVANJA	128
8.1.	Zaključak	128
8.2.	Praktične smjernice za upravljanje imovinom u smislu energetske učinkovitosti i održivosti školskih zgrada.....	131
8.3.	Smjernice za daljnja istraživanja	132
	POPIS LITERATURE	133

POPIS SLIKA

Slika 1 Udio ukupne potrošnje energije u zgradama u ukupnoj potrošnji finalne energije Republike Hrvatske za 2022. godinu [184]	48
Slika 2 Broj javnih zgrada u Republici Hrvatskoj prema godini izgradnje [13]	51
Slika 3 Pozitivna korelacija, negativna korelacija, bez korelacije [209]	66
Slika 4 Arhitektura optimalno odabranog modela neuronske mreže (MLP 3-5-1) za razvoj modela procjene potrošnje električne energije	69
Slika 5 Histogram mjesečne potrošnje vode	77
Slika 6 Histogram mjesečne potrošnje vode po korisniku	77
Slika 7 Histogram godišnje potrošnje vode	78
Slika 8 Histogram godišnje potrošnje vode po korisniku	79
Slika 9 Optimalni odabrani model procjene mjesečne potrošnje vode (MLP 3-4-1)	81
Slika 10 Optimalni odabrani model procjene godišnje potrošnje vode (MLP 3-3-1)	82
Slika 11 Dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje vode u skupu podataka za trening	83
Slika 12 Dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje vode u skupu podataka za validaciju	85
Slika 13 Optimalni odabrani model procjene godišnje potrošnje toplinske energije (MLP 3-6-1)	90
Slika 14 Dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje toplinske energije u skupu podataka za trening	92
Slika 15 Dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje toplinske energije u skupu podataka za validaciju	94
Slika 16 Zastupljenost energetske razreda u uzorku prema proračunskoj i prema stvarnoj potrošnji .	98
Slika 17 Udio vrsta sustava grijanja u analiziranim školama	99
Slika 18 Proračunska i stvarna potrošnja toplinske energije za grijanje za uzorak škola	100
Slika 19 Energetski jaz u uzorku škola	100
Slika 20 Broj školskih zgrada s vrijednostima energetske jaza iznad 30 % prikazan prema godinama izgradnje	104
Slika 21 Učestalost svake od ocjena među analiziranim školama	111
Slika 22 Optimalni odabrani model za predviđanje ukupne ocjene školskih zgrada (MLP 7-11-5)	114

POPIS TABLICA

Tablica 1 Prikaz komponenata u hijerarhijama zgrada.....	11
Tablica 2 Ljestvice ocjenjivanja i njihovi lingvistički prikazi	14
Tablica 3 Sažeti prikaz prethodnih istraživanja o procjeni stanja zgrada	21
Tablica 4 Sažeti prikaz prethodnih istraživanja o procjeni stanja obrazovnih zgrada.....	29
Tablica 5 Sažeti prikaz prethodnih istraživanja o potrošnji energije u obrazovnim zgradama	35
Tablica 6 Sažeti prikaz prethodnih istraživanja o analizi potrošnje vode u obrazovnim zgradama	38
Tablica 7 Sažeti prikaz prethodnih istraživanja o procjeni potrošnje električne i toplinske energije u obrazovnim zgradama	42
Tablica 8 Sažeti prikaz prethodnih istraživanja o procjeni potrošnje vode u obrazovnim zgradama	43
Tablica 9 Projekcija ukupne površine nestambenih zgrada u 2030., 2040. i 2050. godini [13].....	52
Tablica 10 Ploština korisne površine grijanog dijela zgrada (A_k) prema namjeni i razdoblju izgradnje u m^2 [192]	53
Tablica 11 Specifična godišnja potrebna toplinska energija za grijanje (kWh/m^2god) prema namjeni i razdoblju izgradnje zgrade za kontinentalnu Hrvatsku [192].....	53
Tablica 12 Razdoblja i karakteristike izgradnje zgrada u RH [194, 198]	55
Tablica 13 Popis analiziranih osnovnih i srednjih škola na području Osječko-baranjske županije	58
Tablica 14 Identificirane značajne ulazne varijable za razvoj modela procjene potrošnje električne energije.....	63
Tablica 15 Izlazna varijabla za razvoj modela procjene potrošnje električne energije u školskim zgradama	64
Tablica 16 Deskriptivna statistika ulaznih i izlaznih varijabli modela procjene potrošnje električne energije.....	64
Tablica 17 Korelacije ulaznih varijabli s izlaznom varijablom AEC	66
Tablica 18 Izrazi za izračun statističkih tehnika za procjenu pogreške predviđanja	70
Tablica 19 Točnosti razvijenih modela procjene potrošnje električne energije za skup podataka za trening	71
Tablica 20 Točnosti razvijenih modela procjene potrošnje električne energije za skup podataka za validaciju	72
Tablica 21 Identificirane značajne ulazne varijable za razvoj modela procjene potrošnje vode	74
Tablica 22 Izlazne varijable za razvoj modela procjene potrošnje vode.....	74
Tablica 23 Odabrane varijable korištenjem postupne metode regresije za razvoj modela procjene potrošnje vode.....	75
Tablica 24 Deskriptivna statistika ulaznih i izlaznih varijabli modela procjene potrošnje vode.....	75

Tablica 25 Točnosti razvijenih modela procjene mjesečne i godišnje potrošnje vode za skup podataka za trening	82
Tablica 26 Točnosti razvijenih modela procjene mjesečne i godišnje potrošnje vode za skup podataka za validaciju	84
Tablica 27 Identificirane značajne ulazne varijable za razvoj modela procjene potrošnje toplinske energije	86
Tablica 28 Izlazna varijabla za razvoj modela procjene potrošnje toplinske energije	87
Tablica 29 Vrijednosti koeficijena korelacije i opis povezanosti [263]	87
Tablica 30 Korelacije ulaznih varijabli s izlaznom varijablom <i>AHC</i>	88
Tablica 31 Deskriptivna statistika ulaznih i izlaznih varijabli modela procjene potrošnje toplinske energije	88
Tablica 32 Važnosti prediktora ulaznih varijabli modela procjene potrošnje toplinske energije	91
Tablica 33 Točnosti razvijenih modela procjene potrošnje toplinske energije za skup podataka za trening	91
Tablica 34 Točnosti razvijenih modela procjene potrošnje toplinske energije za skup podataka za validaciju	93
Tablica 35 Energetski razredi zgrada [270]	95
Tablica 36 Analiza deskriptivne statistike energetskih certifikata i stvarne potrošnje toplinske energije za grijanje	97
Tablica 37 Deskriptivna statistička analiza energetskog jaza	101
Tablica 38 Deskriptivna statistička analiza energetskog jaza prema vrsti škole	101
Tablica 39 Deskriptivna statistička analiza energetskog jaza prema vrsti grijanja.....	101
Tablica 40 Održivi vijek uporabe analiziranih elemenata [280].....	106
Tablica 41 Ljestvica za ocjenjivanje elemenata	107
Tablica 42 Deskriptivna statistička analiza starosti izgradnje i obnove za uzorak škola	108
Tablica 43 Deskriptivna statistička analiza preostalog održivog vijeka uporabe analiziranih elemenata u uzorku škola	109
Tablica 44 Učestalost kategorija stanja među elementima	110
Tablica 45 Učestalost svake od ocjena među analiziranim školama	111
Tablica 50 Ulazne i izlazne varijable za razvoj modela procjene stanja školskih zgrada.....	112
Tablica 51 Korelacije ulaznih varijabli s izlaznom varijablom <i>Btg</i>	112
Tablica 52 Važnosti prediktora ulaznih varijabli	115
Tablica 53 Točnosti razvijenih modela procjene stanja školskih zgrada u skupu podataka za trening.	116

Tablica 54 Točnosti razvijenih modela procjene stanja školskih zgrada u skupu podataka za validaciju	116
Tablica 55 Popis škola korištenih za validaciju razvijenih modela	118
Tablica 56 Chaddockova ljestvica [289]	120
Tablica 57 Točnosti razvijenih modela procjene potrošnje električne energije u uzorku škola za validaciju	120
Tablica 58 Točnosti razvijenih modela procjene godišnje i mjesečne potrošnje vode u uzorku škola za validaciju	121
Tablica 59 Točnosti razvijenih modela procjene potrošnje toplinske energije u uzorku škola za validaciju	122
Tablica 60 Popis korištenih škola istočne Hrvatske za validaciju razvijenih modela procjene potrošnje toplinske energije	123
Tablica 61 Točnosti razvijenih modela procjene potrošnje toplinske energije u uzorku škola za validaciju iz istočne Hrvatske	124
Tablica 62 Točnosti razvijenih modela procjene stanja u uzorku škola za validaciju.....	125

POPIS KRATICA I SIMBOLA

A	Oplošje grijanog dijela zgrade
AE	Autoencoder (hrv. autoenkoder)
AHP	Analytic Hierarchy Process (hrv. analitički hijerarhijski proces)
AI	Artificial Intelligence (hrv. umjetna inteligencija)
A_k	Ploština korisne površina grijanog dijela zgrada
AMIS	Asset Management Information System (hrv. informacijski sustav za upravljanje imovinom)
ANP	Analytical Network Process (hrv. analitički mrežni proces)
ANN	Artificial Neural Network (hrv. umjetna neuronska mreža)
APN	Agencija za pravni promet i posredovanje nekretninama
BCA	Building Condition Assessment (hrv. procjena stanja zgrade)
BIM	Building Information Modeling (hrv. informacijsko modeliranje građevina)
BMDSS	Building Maintenance Decision Support System (hrv. sustav za donošenje odluka o održavanju zgrada)
CART	Classification and Regression Tree (hrv. model klasifikacije i regresijskog stabla)
CI	Condition Index (hrv. indeks stanja)
CNN	Convolutional Neural Network (hrv. konvolucijska neuronska mreža)
CRV	Current Replacement Value (hrv. trenutna vrijednost zamjene objekta)
CSP	Condition Survey Protocol (eng. Protokol za procjenu stanja)

CVRMSE	Coefficient of the Variation of the Root Mean Square Error (hrv. koeficijent varijacije korijena srednje kvadratne pogreške)
EMIS	Energy Management Information System (hrv. Informacijski sustava za gospodarenje energijom)
f	Udio ploštine prozora u ukupnoj ploštini pročelja
FCI	Facility Condition Index (hrv. indeks stanja objekta)
FM	Facility Management (hrv. održavanje objekata)
f_o	Faktor oblika zgrade
FZOU	Fond za zaštitu okoliša i energetske učinkovitost
GBR	Gradient Boosting Regressor (hrv. gradijentno pojačavanje)
GHG	Greenhouse Gas (hrv. staklenički plinovi)
HVAC	Heating, Ventilation and Air Conditioning (hrv. grijanje, ventilacija i klimatizacija)
HT	Koeficijent transmisijskog toplinskog gubitka
IBIS	Integrated Building Indicator System (hrv. integrirani sustav pokazatelja za zgrade)
IEC	Informacijski sustav energetske certifikata
ISGE	Informacijski sustav za gospodarenje energijom
KPI	Key Performance Indicator (hrv. ključni pokazatelj uspješnosti)
LSTM	Long Short-Term Memory (hrv. mreže s dugom kratkoročnom memorijom)
MAE	Mean Absolute Error (hrv. srednja apsolutna pogreška)
MAPE	Mean Absolute Percentage Error (hrv. srednja apsolutna postotna pogreška)
MAUT	Multiattribute Utility Theory (hrv. višekriterijska teorija korisnosti)

MGIPU	Ministarstvo prostornog uređenja, graditeljstva i državne imovine
MLP	Multi-Layer Perceptron (hrv. višeslojni perceptron)
MLR	Multiple Linear Regression (hrv. višestruka linearna regresija)
MSE	Mean Square Error (hrv. srednja kvadratna pogreška)
MZOE	Ministarstvo zaštite okoliša i energetike
OLS	Ordinary Least Squares (hrv. obična metoda najmanjih kvadrata)
r	Pearsonov koeficijent linearne korelacije
R ²	Coefficient of determination (hrv. koeficijent determinacije)
RF	Random Forest (hrv. algoritam nasumične šume)
RMSE	Root Mean Square Error (hrv. srednja kvadratna pogreška)
RNN	Recurrent Neural Network (hrv. rekurentna neuronska mreža)
nZEB	Nearly Zero Energy Building (hrv. zgrada gotovo nulte energije)
SEM	Structural Equation Modeling (hrv. strukturalni model jednadžbe)
SVM	Support Vector Machine (hrv. stroj s potpornim vektorom)
Ve	Obujam grijanog dijela zgrade
Q'' _{H,nd}	Specifična godišnja potrebna toplinska energija za grijanje

1. UVOD

1.1. Predmet i problem istraživanja

Školske zgrade, kao prostori koji osiguravaju osnovne uvjete za odgoj i obrazovanje, imaju ključnu ulogu u razvoju suvremenog društva [1]. Njihova primarna funkcija nije samo omogućavanje obrazovanja, već i stvaranje sigurnog, zdravog i stimulativnog okruženja za učenike i nastavnike [2]. Međutim, upravljanje školskim zgradama često je povezano s raznim izazovima, uključujući zastarjelost građevinskih elemenata, neodgovarajuće sustave održavanja i povećane zahtjeve za energetsom učinkovitošću, a takvi izazovi posebno dolaze do izražaja u zemljama i regijama s dugotrajnim razdobljima ekonomske stagnacije, gdje je ulaganje u obrazovnu infrastrukturu često bilo nedovoljno [3]. Jedan od ključnih aspekata povezanih s kvalitetom školskih zgrada je njihovo fizičko stanje. Tijekom vremena, građevinski materijali degradiraju, što može rezultirati pojavom pukotina, oštećenjem nosivih elemenata, gubitkom izolacijskih svojstava i raznim drugim problemima [4]. To je posebno izraženo kod zgrada izgrađenih prije nekoliko desetljeća, kada standardi izgradnje nisu uzimali u obzir suvremene zahtjeve za održivošću i energetsom učinkovitošću. Procjena stanja takvih zgrada zahtijeva sveobuhvatan i sustavan pristup, koji uključuje analizu elemenata, materijala i njihovih performansi tijekom vremena [5]. Uz procjenu fizičkog stanja, jednako je važna analiza energetske performansi školskih zgrada. Školske zgrade, zbog svoje funkcionalne specifičnosti, koriste značajne količine energije za grijanje i hlađenje te koriste značajnu količinu vode [6]. Mnoge od njih ne zadovoljavaju suvremene energetske standarde, što dovodi do povećane potrošnje resursa i viših uporabnih troškova.

Na globalnoj razini, smanjenje energetske potrošnje u zgradarstvu prepoznato je kao jedan od ključnih koraka u postizanju ciljeva održivog razvoja i borbi protiv klimatskih promjena [7]. U tom kontekstu, školske zgrade, kao javni objekti, predstavljaju važno područje intervencije. Razlika između stvarne i proračunske potrošnje energije u školskim zgradama često ukazuje na neprimjerenu kontrolu i upravljanje resursima. Pitanje održivosti školskih zgrada uključuje i širi društveni kontekst. Poboljšanje njihovog fizičkog stanja i energetske učinkovitosti ne samo da doprinosi sigurnijem i ugodnijem okruženju za korisnike, već ima i širi utjecaj na lokalnu zajednicu. Smanjenje potrošnje energije i vode direktno utječe na smanjenje emisija stakleničkih plinova i na financijske uštede, koje se potom mogu reinvestirati u obrazovni sustav [8]. Istovremeno, obnovljene i funkcionalne zgrade mogu potaknuti povećanje svijesti o važnosti održivog upravljanja resursima među učenicima i nastavnicima [9]. Upravljanje školskim zgradama zahtijeva integrirani pristup koji obuhvaća više dimenzija – od tehničke procjene stanja i energetske analiza do strateškog planiranja i upravljanja [10].

Prema podacima Europske komisije, većina zgrada u Europskoj uniji (EU), točnije 85 %, izgrađena je prije 2000. godine [11]. Osim toga, značajnih 75 % zgrada ima neodgovarajuću energetska učinkovitost. Poduzimanje mjera za poboljšanje energetske učinkovitosti zgrada ključno je za očuvanje energije i postizanje cilja da zgrade do 2050. godine ne proizvode emisije ugljikovog dioksida i budu potpuno dekarbonizirane. Do 11. listopada 2025. godine, države članice EU bit će obvezne izraditi i javno objaviti sveobuhvatan popis zgrada u vlasništvu ili pod korištenjem vladinih tijela s ukupnom korisnom površinom većom od 250 m² koji se mora ažurirati najmanje jednom svake dvije godine [12]. Osim toga, Direktiva o energetska učinkovitosti zgrada (2010/31/EU), kako je izmijenjena Direktivom (2018/844/EU), zahtijeva od zemalja EU da razviju nacionalne dugoročne strategije za obnovu, koje moraju uključivati politike i akcije usmjerene na sve javne zgrade [12]. U Hrvatskoj su 2018. godine nestambene zgrade činile 28 % površine svih zgrada. Među zgradama u ovoj skupini, obrazovne zgrade imaju visok postotak – 10 % ukupne površine nestambenih objekata. Očekuje se da će obrazovne zgrade zadržati ovaj trend, s konstantnim predviđanjima udjela od 10 % i u 2030., 2040. i čak 2050. godini [13]. Budući da obrazovne zgrade čine značajan udio nestambenih zgrada, važno je usmjeriti inicijative za uštedu energije na ove objekte [14-16]. Osim energije, važno je promatrati i potrošnju vode u obrazovnim zgradama s obzirom na to da Boretti i Rosa ističu da je globalna potražnja za vodom porasla za 600 % u posljednjih 100 godina [17]. Ovaj trend može se primijetiti i u Republici Hrvatskoj, gdje je u posljednje tri godine količina isporučene vode iz javne vodoopskrbe u Hrvatskoj kontinuirano rasla [18].

Energetske karakteristike, svojstva i potrošnja energije zgrada uvelike ovise o razdoblju izgradnje zgrade te o postojanju i primjeni propisa o toplinskoj izolaciji [19]. Odsutnost ili neprimjerenost regulativnih mjera glavni su razlog zbog kojeg značajan broj starijih zgrada, izgrađenih prije mnogo godina, ima značajan negativan utjecaj na okoliš i pokazuje visoke razine potrošnje energije [20]. Republika Hrvatska ima visoku potrošnju energije zbog velikog broja zgrada izgrađenih tijekom brzog rasta stanovništva i izgradnje zgrada u prvoj polovici 20. stoljeća, posebno u 1960-im, 1970-im i ranim 1980-im godinama. Tijekom ovog razdoblja, zakoni o energetska učinkovitosti i toplinskoj izolaciji zgrada bili su nedovoljni u usporedbi s trenutačnim. Stoga, prevladavajući udio zgrada izgrađen je prije i tijekom 1970-ih godina 20. stoljeća (54 %), prije sustavne primjene zakonodavstva vezanog uz toplinsku izolaciju zgrada [21].

Razvoj modela procjene potrošnje energije i procjene stanja školskih zgrada predstavlja ključan korak prema uspostavi sustavnog i integriranog pristupa upravljanju obrazovnom infrastrukturom. Takvi modeli omogućuju brzo i precizno mapiranje trenutačnog stanja zgrada i identifikaciju ključnih problema. Razvoj i implementacija ovih modela u Hrvatskoj može imati dugoročne koristi. Osim smanjenja uporabnih troškova i unaprjeđenja sigurnosti zgrada, modeli omogućuju usklađivanje s

nacionalnim i EU ciljevima održivog razvoja te povećavaju transparentnost i odgovornost u upravljanju javnim resursima.

1.2. Ciljevi i hipoteze istraživanja

Opći ciljevi ovog istraživanja su:

- prikupljanje povijesnih podataka o geometrijskim, materijalnim i uporabnim karakteristikama školskih zgrada u Osječko-baranjskoj županiji,
- prikupljanje povijesnih podataka o potrošnji energije, energenata i vode u školskim zgradama u Osječko-baranjskoj županiji,
- utvrđivanje razlike između stvarne i proračunske potrošnje energije školskih zgrada u Osječko-baranjskoj županiji i uzroka pojave razlike,
- istraživanje utjecaja geometrijskih, materijalnih i uporabnih karakteristika školskih zgrada u Osječko-baranjskoj županiji na potrošnju energije, energenata i vode u tim zgradama,
- istraživanje utjecaja geometrijskih, materijalnih i uporabnih karakteristika školskih zgrada u Osječko-baranjskoj županiji na stanje školskih zgrada u Osječko-baranjskoj županiji.

Specifični cilj ovog istraživanja je razvoj i definicija novih matematičkih modela koji će se moći koristiti za učinkovito upravljanje imovinom kroz procjenu potrošnje energije, energenata i vode te procjenu stanja školskih zgrada u Osječko-baranjskoj županiji.

Definirane su sljedeće hipoteze istraživanja:

- Moguće je izraditi nove matematičke modele procjene potrošnje energije, energenata i vode na temelju utjecaja geometrijskih, materijalnih i uporabnih karakteristika zgrada.
- Moguće je uspostaviti sustav procjene stanja školskih zgrada koji će se temeljiti na prethodno utvrđenim karakteristikama uzorka.

1.3. Metode istraživanja

Plan istraživanja sastoji se od sljedećih koraka:

- Prvi korak obuhvaća analizu relevantne literature i prethodnih istraživanja koja se bave procjenom stanja zgrada i potrošnjom energije u zgradama uz poseban naglasak na školske zgrade s ciljem stjecanja uvida u trenutačno dostupne informacije i spoznaje na tu temu.

Korištenjem znanstvenih metoda za pregled i analizu relevantne literature te primjenom analize i sinteze bit će identificirani predmet i problem istraživanja. Također, definirat će se ciljevi i postaviti hipoteze istraživanja.

- U drugom koraku provest će se prikupljanje i selekcija podataka o materijalnim, geometrijskim i uporabnim karakteristikama zgrada i potrošnji energije, energenata i vode školskih zgrada u Osječko-baranjskoj županiji. Podaci o navedenim karakteristikama te potrošnji energije, energenata i vode u zgradama bit će prikupljeni iz energetske certifikate školskih zgrada (prikupljenih direktno od škola, od Ministarstva prostornoga uređenja, graditeljstva i državne imovine te s Informacijskog sustava energetske certifikate) kao i iz Informacijskog sustava za gospodarenje energijom (ISGE).
- U trećem koraku utvrdit će se razlika između stvarne potrošnje energije školskih zgrada te proračunske potrošnje energije izražene u energetskim certifikatima predmetnih zgrada.
- U četvrtom koraku provest će se statistička analiza podataka te će se interpretirati rezultati u vezi s karakteristikama školskih zgrada i potrošnjom energije, energenata i vode u školskim zgradama u Osječko-baranjskoj županiji. Cilj je identificirati uzorke, korelacije i razlike između karakteristika školskih zgrada u Osječko-baranjskoj županiji, njihova stanja te njihove potrošnje energije, energenata i vode.
- U petom koraku, nakon analize prikupljenih podataka, slijedi izrada i testiranje matematičkih modela za procjenu potrošnje energije, energenata i vode te sustava za procjenu stanja školskih zgrada u Osječko-baranjskoj županiji korištenjem prikupljenih podataka kao osnovom za modeliranje.
- Šesti korak obuhvaća donošenje zaključaka te definiranje preporuka i smjernica za daljnja istraživanja. Ovaj korak ima za cilj sintetizirati dobivene spoznaje i pružiti smjernice za praktičnu primjenu u upravljanju školskim zgradama.

1.4. Struktura doktorskog rada i očekivani znanstveni doprinos

Struktura doktorskog rada oblikovana je prema Uputama za izradu i oblikovanje doktorske disertacije Građevinskog i arhitektonskog fakulteta Osijek, Sveučilišta Josipa Jurja Strossmayera u Osijeku.

Rad se sastoji od predgovora, sažetka na hrvatskom i engleskom jeziku, sadržaja, popisa slika, popisa tablica, popisa kratica i simbola, glavnog teksta te citirane literature i priloga. Korišteni stručni strani pojmovi prevedeni su na hrvatski jezik. Glavni tekst rada sastoji se od osam poglavlja.

U prvom poglavlju predstavljeni su predmet i problem istraživanja, definirani su ciljevi i postavljene hipoteze istraživanja. Objašnjene su metode istraživanja i koraci istraživanja s pomoću kojih će se ostvariti definirani ciljevi te dokazati postavljene hipoteze.

U drugom poglavlju predstavljen je pregled relevantne literature i prethodnih istraživanja koja se bave procjenom stanja zgrada i potrošnjom energije u zgradama uz poseban naglasak na školske zgrade. Predstavljen je pojam procjene stanja zgrada, hijerarhija koja se koristi pri procjeni, ljestvice stanja i njihovi lingvistički prikazi te prethodna istraživanja vezana uz procjenu stanja zgrada i procjenu stanja obrazovnih zgrada.

U trećem poglavlju istaknuta je važnost analize potrošnje energije, energenata i vode u obrazovnim zgradama te su predstavljena prethodna istraživanja na temu analize i procjene potrošnje energije, energenata i vode u obrazovnim zgradama. Osim toga, definiran je pojam energetskog jaza i prethodna istraživanja koja su se njime bavila.

U četvrtom poglavlju predstavljen je pregled stanja i zakonodavnog okvira u Republici Hrvatskoj te podaci o javnim zgradama za obrazovanje u Republici Hrvatskoj. Osim toga, predstavljen je način prikupljanja podataka o geometrijskim, materijalnim i uporabnim karakteristikama školskih zgrada u Osječko-baranjskoj županiji te o njihovoj potrošnji energije, energenata i vode.

U petom poglavlju predstavljaju se razvijeni modeli i to prvo za procjenu godišnje potrošnje električne energije školskih zgrada (koristeći višestruku linearnu regresiju i neuronsku mrežu), a zatim i za procjenu mjesečne i godišnje potrošnje vode školskih zgrada (koristeći višestruku linearnu regresiju i neuronske mreže). Nadalje, za procjenu godišnje potrošnje toplinske energije školskih zgrada (koristeći višestruku linearnu regresiju, neuronsku mrežu te algoritam nasumične šume). Po pojedinim potpoglavljima dane su i usporedbe točnosti modela razvijenih različitim metodama. Naposljetku, provedena je usporedba stvarne i proračunske potrošnje toplinske energije školskih zgrada, analiza energetskog jaza te analiza uzroka njegove pojave.

U šestom poglavlju predstavljen je razvoj sustava procjene stanja školskih zgrada. Prvo je razvijen model za procjenu stanja na razini pojedinih elemenata, a zatim su predstavljena dva modela za procjenu stanja na razini cijele zgrade. Jedan model koristi neuronske mreže, dok drugi koristi algoritam nasumične šume. U ovom dijelu rada uspoređivana je točnost oba modela.

U sedmom poglavlju provedena je validacija razvijenih modela procjene potrošnje električne energije, mjesečne i godišnje potrošnje vode, potrošnje toplinske energije te sustava procjene stanja školskih

zgrada na uzorku škola izvan Osječko-baranjske županije koji uključuje škole kontinentalne i primorske Hrvatske.

U osmom poglavlju dani su zaključci istraživanja, praktične smjernice za upravljanje školskim zgradama te smjernice za daljnja istraživanja.

Očekivani znanstveni doprinos ovog rada je:

- Razvoj i definicija novih matematičkih modela za procjenu potrošnje energije, energenata i vode, te sustava za procjenu stanja školskih zgrada, koji se temelje na specifičnim karakteristikama zgrada.
- Identifikacija ključnih geometrijskih, materijalnih i uporabnih parametara koji značajno utječu na potrošnju resursa i stanje školskih zgrada, što može pomoći u optimizaciji upravljanja zgradama.
- Utvrđivanje razlike između stvarne i proračunske potrošnje energije školskih zgrada i uzroka te razlike.

Praktični doprinos ovog rada su praktične smjernice za upravljanje imovinom u smislu energetske učinkovitosti i održivosti školskih zgrada, temeljene na modelima i analizama.

2. PREGLED DOSADAŠNJIH ISTRAŽIVANJA O PROCJENI STANJA ZGRADA

2.1. Definicija procjene stanja zgrada

Unatoč njihovom velikom kulturnom, ekonomskom i povijesnom značaju, istraživanja su pokazala da veliki broj zgrada brzo propada zbog starosti i preopterećenja [22]. Preopterećenje u ovom kontekstu odnosi se na stanje kada zgrada, zbog povećanog broja korisnika, nepravilne upotrebe ili nedostatka održavanja, doživljava veće fizičko ili funkcionalno opterećenje od onog na koje je bila projektirana, što može ubrzati njezino propadanje. Procjene stanja zgrada (engl. *Building Condition Assessments* (BCAs)) koriste se kako bi se mjerljivo ocijenilo propadanje s ciljem prikupljanja podataka za utvrđivanje potrebe i trenutka za prediktivne, preventivne ili korektivne aktivnosti, kako bi se ocijenila i održala željena razina korištenja zgrade [23]. Procjena stanja zgrade pruža trenutačan prikaz stanja zgrade kako bi se odredile potrebe za kapitalnim proračunom za veće popravke i zamjene tijekom određenog razdoblja. Procjena stanja stoga pomaže upraviteljima zgrada da odrede prioriteta sredstva za popravke i zamjene. Općenito, procjena stanja zgrade je ocjena koja identificira veće nedostatke za sve sustave u zgradi. Sustavi uključeni u procjenu stanja mogu obuhvaćati: mehaničke sustave, vanjske dijelove odnosno ovojnici zgrade, konstrukcijske sklopove, krovne sustave, sustave za zaštitu od požara i sustave sigurnosti, električne sustave, transportne sustave, unutarnje završne radove i vodovodne sustave, a ponekad se proširuju i na instalacije, opremu i namještaj [24].

Procjena stanja u literaturi je definirana na različite načine:

- Alat za ocjenjivanje tehničke izvedbe zgrada kako bi se poduprla očekivanja dugoročnog održavanja [25].
- Ocjenjivanje stanja funkcionalnog sustava koji ispunjava željene ciljeve [26].
- Usluga koju pružaju stručnjaci koja uključuje izvođenje revizija zgrada, uglavnom radi izvještavanja o nedostacima zgrade, s ciljem podizanja performansi zgrade na njezinu izvornu "novu" razinu [27].
- Pregled sustava zgrade radi procjene trenutačnog stanja sustava na temelju utvrđenih mjera stanja [28].
- Sredstvo za stvaranje potpunog popisa nedostataka u zgradi temeljito procjenjujući postojeće fizičko stanje i funkcionalnu izvedbu zgrade, opreme, instalacija i okoliša [29].

- Proces sustavne evaluacije kapitalnih sredstava organizacije kako bi se predvidjele potrebe za popravkom, obnovom ili zamjenom koje će očuvati njihovu sposobnost očuvanja misije ili aktivnosti za koje su namijenjene [30].
- Informacijski sustav prilagođen za unos, pohranu, manipulaciju i izvješćivanje o informacijama povezanim s objektima [31].
- Proces inspekcije i izvješćivanja o fizičkom stanju i funkcionalnoj izvedbi zgrada i infrastrukturnih sustava i komponenata [32].
- Proces u kojem se sustavi, komponente i potkomponente organizacije ocjenjuju u pogledu njihovog stanja [33].
- Korištenje sustavnog postupka dizajniranog za proizvodnju proporcionalnih, relevantnih i korisnih informacija kako bi se provela tehnička procjena fizičkog stanja imovine [34].

Nedostatak zgrade je prema ISO 15686-1:2011 definiran kao pogreška ili odstupanje od predviđene razine izvedbe zgrade ili njezinih dijelova [35], dok je u literaturi definiran na razne načine kao što su: Oštećenje koje ugrožava kvalitetu zgrade ili njezinog dijela [36]; Pojam koji se koristi za definiranje kvara ili manjkavosti u funkciji, izvedbi, zakonskim ili korisničkim zahtjevima zgrade te se može očitovati unutar strukture, materijala, usluga ili drugih dijelova oštećene zgrade [37]; Stupanj nesavršenosti promatrane zgrade na zastarjelom elementu ili komponenti koji utječe na funkcionalnost, uporabljivost i izvedbu zgrade [38].

Sugerira se da je idealno stanje zgrade ocjenjivati jednom godišnje jer što je dulje razdoblje između inspekcija, inspekcija postaje sve obimnija. Međutim, ograničavajući faktor prilikom razmatranja učestalosti ocjena stanja je trošak inspekcije, a informacije odgovarajuće razine detaljnosti moraju biti prikupljene tijekom terenske inspekcije. Prikupljanje prekomjerno detaljnih informacija, koje se nakon toga ne koriste, je nepotrebno dok s druge strane, nedostatak detalja također nije dobar jer prikupljeni podaci mogu biti neupotrebljivi s obzirom na to da nisu dostatni [33].

Što se tiče donošenja odluka, stručnjaci predlažu razvoj programa upravljanja imovinom. Taj program obuhvaća politike, ciljeve i strategije prije nego što se krene u konkretni plan upravljanja imovinom. U tom kontekstu, informacijski sustavi za upravljanje imovinom (engl. *Asset Management Information Systems* (AMIS)) ključna su tema s obzirom na to da uključuju tehničke, financijske i povijesne informacije o imovini. Ti sustavi mogu varirati u sofisticiranosti, od jednostavnih tablica koje su u širokoj upotrebi do naprednih sustava koji koriste specifične modele za predviđanje budućih stanja [39]. Takvi modeli pružaju najrobusniju analizu i sposobnosti predviđanja budućih stanja imovine, uključujući njezinu degradaciju, troškove održavanja, potrebne investicije i optimalne strategije upravljanja tijekom životnog ciklusa [40].

Međutim, upravitelji zgrada suočavaju se s preprekama koje ometaju provedbu tih modela predviđanja. Nedostatak informacija o trenutačnom stanju imovine uzrokuje neuspjeh u razvoju takvih modela [41], a time i nemogućnost usvajanja općenitog pristupa za procjenu potkomponenti zgrada [34]. Pojedina istraživanja su predložila pristupe za procjenu komponenata infrastrukture i njihovog prioriteta za održavanje [41]. Međutim, takvi napori zanemaruju problem kako bi se ta procjena mogla primijeniti na razinu zgrade i pružiti više od jednostavnog prikaza zgrade što naglašava potrebu za općim i pojednostavljenim pristupom procjene stanja elemenata koji se može primijeniti na razini zgrade [42].

Postoji mnogo pristupa provođenju procjene stanja, a jedan od njih je da se procjena može provoditi na razini komponente, gdje se procjenjuje svaki komad opreme, a vrednuje se vrijednost i preostali vijek trajanja opreme [43]. Osim toga, može se provoditi i na razini sustava, gdje se naglasak stavlja na dodjeljivanje ocjene cjelokupnom sustavu, umjesto dodjeljivanja vrijednosti njegovom nizu komponenata. Postoje i statistički pristupi kao što su parametričke metode, gdje se podaci prikupljaju za dio sredstava organizacije i rezultati se ekstrapoliraju na cijeli inventar zgrada.

Nakon provedene procjene stanja zgrade, podaci dobiveni tim procesom analiziraju se i pretvaraju u vrijednost stanja ili indeks zvan indeks stanja objekta (engl. *Facility Condition Index* (FCI)), koji se smatra standardnim alatom u održavanju objekata (engl. *Facility Management* (FM)) i koristi se za usporedbu stanja objekata te određivanje ekonomske isplativosti potpunog moderniziranja/renovacije postojećeg objekta ili njegove zamjene [24]. FCI se izračunava omjerom između troška popravka nedostataka (ili odgođenog održavanja) i trenutačne vrijednosti zamjene objekta (engl. *Current Replacement Value* (CRV)). Trošak za popravak nedostataka predstavlja procijenjeni ukupni trošak za popravak svih nedostataka u životnom ciklusu i održavanju dok je vrijednost zamjene trošak zamjene postojeće konstrukcije novom istih dimenzija i na istoj lokaciji [44]. Međutim, izračun FCI-a varira od institucije do institucije, kao i od jedne konzultantske tvrtke do druge. Skala mjerenja također varira, čime se FCI čini manje pouzdanim kao alat za usporedbu, gdje se uspoređuju objekti u vlasništvu različitih entiteta ili objekti unutar istih naselja, čija je procjena stanja provedena od strane različitih konzultanata koji koriste različite formule za izračun FCI-a [45].

Ocjenjivanje, odnosno procjenu stanja, može provesti vanjski konzultant ili interni član osoblja, a prilikom određivanja tko će provesti postupak ocjene, trošak je glavna ograničavajuća okolnost. Manje organizacije si vjerojatno neće moći priuštiti stručnjaka, dok veće organizacije mogu zaposliti nekoliko njih samo u tu svrhu. Međutim, važno je da tim za ocjenu stanja poznaje osnove održavanja i operacija objekata i da ima dovoljno vremena za pravilno obavljanje zadatka [46].

Od 1980-ih godina razvijani su sustavi za ocjenjivanje stanja namijenjeni pojedinim vrstama građevina i komponentata. Primjerice, PAVER je razvijen za upravljanje asfaltom [47], RAILER za željezničke pruge [48], BRIDGER za mostove [49], ROOFER za krovove [50], a GRIPPER za podzemne plinske cijevi [49]. Za zgrade razvijeni su:

- BUILDER koji je razvila vojska Sjedinjenih Američkih Država (SAD-a) u Inženjerskom centru za istraživanje i razvoj. BUILDER pruža inženjerima i upraviteljima zgrada alat koji pomaže u procesu donošenja odluke o tome kada, gdje i kako najbolje održavati zgrade i njihove ključne komponente. Temeljen je na sustavu Windows®, s funkcijama koje uključuju inventar glavnih komponentata zgrada, inspekcije u obliku obrazaca, ocjene stanja, ocjene funkcionalnosti i mogućnosti predviđanja stanja [51, 52].
- RECAPP® (*Re-Engineering the Capital Asset Priority Plan*) je prvotno razvijen kako bi podržao prikupljanje podataka i izvješćivanje za klijente koji provode reviziju. Uključuje inventar glavnih komponentata zgrada, inspekcije u obliku obrazaca i ocjene stanja. U širokoj je upotrebi za školske odbore, upravljanje komunalnom infrastrukturuom i vlasnike zračnih luka [24].
- TOBUS je razvila Europska komisija u okviru programa JOULE III, a njegova ocjena stanja obuhvaća stupanj i opseg fizičkog propadanja te radove potrebne za obnovu uredskih zgrada [53].

U RECAPP sustavu, svaka komponenta ima zaseban popis specifičnih nedostataka, s težinama koje odražavaju njihov relativni utjecaj na stanje. Na terenu, inspektori procjenjuju ozbiljnost svakog mogućeg nedostatka, a zatim RECAPP izračunava indeks stanja. BUILDER koristi svojih 20 generičkih tipova oštećenja u procesu ocjene. Na terenu, inspektor ocjenjuje svaku potkomponentu u odnosu na tih 20 tipova oštećenja pružajući svoju ocjenu za dvije mjere – broj i razmjer oštećenja. Međutim, ovaj proces je kompliciran i vremenski zahtjevan. Primjerice, kako bi ocijenio komponentu sa samo tri potkomponente, inspektor mora provesti $20 \cdot 2 \cdot 3 = 120$ subjektivnih mjerenja, na temelju kojih se izračunava indeks stanja. TOBUS koristi pristup izravne ocjene stanja za procjenu stanja građevinskih komponentata. TOBUS ocjenjuje trenutačno stanje koristeći četiri koda degradacije kako bi dijagnosticirao razinu fizičkog propadanja zgrade. Međutim, nedostatak ove metode je taj što komponente nisu razložene kao u BUILDER-u i RECAPP-u. Osim toga, ocjena komponentata je vrlo subjektivna jer, za razliku od BUILDER-a i RECAPP-a, TOBUS nema numeričku ljestvicu [46].

2.2. Hijerarhija pri procjeni stanja zgrada

Uzarsky i Burley navode da se kao ključni korak u ocjeni stanja, zgrada mora hijerarhijski razložiti na svoje glavne komponente. Hijerarhija se koristi kao način za klasificiranje i grupiranje tih komponenata u različite kategorije. Na primjer, zgrada se može podijeliti na različite sustave (električni, mehanički, itd.), koji se dalje mogu podijeliti na detaljniju razinu komponenata (unutarnja vrata, vanjska vrata, prozori, stropovi, itd.). Grupiranje komponenata u granu hijerarhije može se provesti kako bi se odražavale slične karakteristike (npr. materijali) ili slične potrebe za inspekcijom [51]. Za objektivnu procjenu zgrade, Straub tvrdi da je potrebna dobro definirana i hijerarhijska klasifikacija komponenata zgrade [54]. Elhakeem je kombinirao prednosti postojećih hijerarhija i predložio hijerarhiju zgrade s pet razina (sustav, podsustav, komponenta, tip/element i instanca) kako bi odgovarala organizacijskoj strukturi organizacije za obrazovanje (npr. školski odbori). Glavne prednosti predložene hijerarhije su olakšavanje procesa revizije ocijenjenih komponenata, ocjenjivanje performansi svakog odjela u održavanju svojih komponenata u sigurnom i zadovoljavajućem stanju te omogućavanje organizacije alokacije sredstava među različitim sustavima prema organizacijskim preferencijama [39]. Uzarski [52] ističe da se stanje pojedinačne komponente zgrade može ocijeniti jednim ili oba pristupa: istraživanjem oštećenja i izravnom ocjenom stanja pri čemu je postupak istraživanja oštećenja točan i reproducibilan pristup s obzirom na to da pruža zapis o tome što treba popraviti. Pristup izravne ocjene stanja manje je točan, ali znatno brži te uključuje vizualni pregled svake komponente i ocjenu prema nizu kriterija. Autor također navodi da odluka o upotrebi izravne ocjene stanja ili pristupa istraživanju oštećenja zahtijeva poznavanje svrhe ocjene. Ako je svrha samo utvrditi stanje komponente, tada je izravna ocjena stanja dovoljna. Međutim, ako je svrha identificirati trenutačne probleme, tada bi trebao biti korišten pristup istraživanju oštećenja [52].

Hijerarhija zgrade različitih modela ocjenjivanja prikazana je u tablici 1. Portugalska metoda procjene stanja podijelila je cijelu zgradu na tri grupe i 37 elemenata [55], dok je nizozemska metoda koristila četiri kategorije i 17 elemenata [54]. Eweda i sur. [5] podijelili su zgradu na četiri kategorije i 17 komponenata, dok su Ho i sur. [56] predložili model ocjenjivanja koji je podijelio zgradu na dvije grane, pet kategorija i 17 komponenata.

Tablica 1 Prikaz komponenata u hijerarhijama zgrada

Izvor	Godina	Tip zgrade	Hijerarhija
<i>National Center for Education Statistics</i> [44]	2003	Obrazovna	11 sustava i 106 komponenata

Ho i sur. [56]	2005	Stambena	dvije grane, pet kategorija i 17 komponenata
Pedro i sur. [55]	2008	Stambena	tri grupe i 37 elemenata
Straub [54]	2009	Stambena	četiri kategorije i 17 elemenata
Eweda [5]	2015	Obrazovna	četiri kategorije i 17 komponenata

Iz navedenoga može se zaključiti da ne postoji zajednička standardna hijerarhija komponenata zgrade koja se koristi. Idealno, hijerarhija zgrade trebala bi biti dosljedna i logična kako bi se komponente lako mogle pratiti u velikoj zgradi, a prikladan mehanizam za ocjenjivanje komponenata zgrade trebao bi nadopunjavati sveobuhvatnu hijerarhiju zgrade kako bi se postigao učinkovit i pouzdan sustav ocjenjivanja [57]. Prethodna istraživanja su pokazale da razvoj hijerarhije zgrade predstavlja neizostavan dio postupka procjene ocjene komponenata zgrade. Moguće je da će pregled istih nedostataka u komponentama zgrade s istim ocjenjivačkim metodama, ali s različitim hijerarhijama, dovesti do varijabilnih ocjena stanja. Hijerarhija zgrade može imati značajne posljedice prilikom agregacije ocjena komponenata radi procjene ukupnih ocjena zgrade. Da bi se postigla objektivna ocjena, osoblju za inspekciju zgrade potrebna je dobro definirana hijerarhijska klasifikacija komponenata zgrade [57].

Velik broj istraživanja usmjeren je prema identificiranju odgovarajućih kriterija za ocjenu performansi građevinskih komponenata. Međutim, bez obzira na kriterije koji se koriste i njihovu razinu detalja, rezultati procesa ocjene vrlo ovise o točnosti subjektivnog procesa terenske inspekcije. Većinom, postojeći sustavi zahtijevaju iskusnog inspektora za ocjenjivanje, u odnosu na bilo koji kriterij. Utvrđuje se stanje tijekom samog procesa inspekcije te su stoga takvi pregledi vrlo skupi i zahtijevaju puno vremena [58].

Neovisno o metodi koja se koristi za zabilježavanje stanja zgrade, postoji niz problema povezanih s terenskom inspekcijom. Jedan od glavnih problema identificiranih u literaturi je subjektivnost inspektora u ocjeni stanja komponente ili sustava [59]. Ta subjektivnost može biti posljedica specifičnog iskustva inspektora, stava prema riziku i pristranosti [60, 61].

Tradicionalno, ocjena stanja zgrade provodi se putem vizualne inspekcije stručnjaka u određenim sustavima zgrade, npr. arhitektonskim, konstrukcijskim, električnim i mehaničkim. Iako mnogi sustavi upravljanja objektima uključuju neke mjere kako bi se osigurala usporedivost, kao što su obuka osoblja i korištenje numerički temeljenog sustava ocjenjivanja, trenutačni proces ocjene stanja i dalje je izrazito subjektivan, a njegova točnost ovisi o iskustvu i obuci terenskih inspektora i ocjenjivača [24].

Faqih i Zayed proveli su komparativnu analizu postojećih modela ocjenjivanja stanja građevinskih komponenata, praćenu njihovom kritičkom analizom te usporedbom sličnosti, razlika i ograničenja. Analizom različitih sustava ocjenjivanja utvrđene su sličnosti među sustavima kao što su: ocjenjivanje stanja zgrade dijeljenjem cijele zgrade na manje komponente unutar hijerarhije, ocjenjivanje ozbiljnosti nedostataka zgrade uporabom ocjenjivačke skale te korištenje težinskih koeficijenata kako bi se odredio relativni značaj svake komponente za ocjenu u konačnoj ocjeni. Kao glavne razlike između različitih sustava utvrđeni su: ciljevi i opseg ocjenjivanja, različite metodologije, alati i tehnike korištene za ocjenu cijele zgrade. Osim toga, utvrđeno je da su procesi za ocjenu građevinskih komponenata uvelike subjektivni jer je većina sustava ocjenjivanja temeljena na vizualnom promatranju i tumačenju inspekcijskog osoblja. Autori naglašavaju da se postojeće prakse inspekcije i metodologije ocjenjivanja mogu poboljšati kako bi se skratilo potrebno vrijeme, smanjili troškovi i subjektivnost u ocjeni građevinskih komponenata, praćeno njihovom kritičkom analizom te usporedbom sličnosti, razlika i ograničenja [57].

Osim toga, autori su utvrdili da je vrlo malo razvijenih zemalja usvojilo sustav ocjenjivanja komponenata zgrada kao zakonski zahtjev, što potiče vlasnike zgrada i upravitelje objekata da ga prihvate. Subjektivnost procjene temeljene isključivo na vizualnom promatranju, vrijeme koje je potrebno i visoki troškovi inspekcije velikog broja komponenata mogu biti razlozi koji i dalje odvrćaju upravitelje objekata od usvajanja sustava ocjenjivanja komponenata zgrade gdje ono nije zakonski obvezujuće. Autori ističu da je potrebno razviti ekonomičan i pouzdan sustav ocjenjivanja komponenata zgrade koristeći dosljedne metode i mjere sa smanjenim troškovima i kraćim trajanjem inspekcije kako bi se postiglo održivo upravljanje [57].

Na temelju provedenog istraživanja, autori su dali preporuke za razvoj novog učinkovitog sustava ocjenjivanja komponenata zgrade. Sustav ocjenjivanja trebao bi se temeljiti na dosljednim hijerarhijama zgrada, a rezultati dobiveni ocjenama trebali bi biti ponovljivi koristeći isti standardni postupak. Autori ističu da bi postupak ocjenjivanja trebao biti jednostavan za korištenje s lako razumljivim ocjenjivačkim skalama radi prihvatanja u krugu stručnjaka. Iako je teško izbjeći subjektivnost zbog ljudskog faktora tijekom ocjenjivanja komponenata zgrade, treba obratiti pažnju na smanjenje subjektivnosti koliko god je moguće i proces učiniti što objektivnijim. Model ocjenjivanja trebao bi zabilježiti trenutačno stanje komponenata zgrade uz trenutačno znanje i ograničenja, ali uz odredbe za buduća poboljšanja. Osim toga, proces ocjenjivanja i procjene trebao bi biti transparentan i otvoren za buduća ispitivanja kako bi se lako otkrile eventualne greške tijekom inspekcije [57].

2.3. Ljestvice ocjenjivanja stanja zgrada i lingvistički prikazi

U svakom sustavu, vrijednosti indeksa stanja pružaju sredstva za usporedbu stanja različitih komponenata. Skala indeksa stanja za građevinske komponente obično se kreće od 0 do 100, gdje 0 predstavlja kritično (kvar) stanje, a 100 predstavlja novo stanje [42]. Bez obzira na numeričku ljestvicu koja se koristi, lingvistički prikaz može se izvesti iz numeričkih vrijednosti [46].

Ostali primjeri ljestvica stanja i odgovarajućih lingvističkih prikaza na temelju pregleda literature prikazani su u tablici 2.

Tablica 2 Ljestvice ocjenjivanja i njihovi lingvistički prikazi

Izvor	Godina	Tip objekta	Ljestvica stanja	Lingvistički prikaz
Pontis baza podataka [62, 63]	1995	Mostovi	1-5	Propadanje: (1 = zaštićeno, 2 = izloženo, 3 = osjetljivo, 4 = napadnuto, 5 = oštećeno)
ADOE [46]	1997	Zgrade	1-4	Kategorija stanja: (1 = dobro, 2 = zadovoljavajuće, 3 = loše, 4 = neprihvatljivo)
Greimann i sur. [64]	1997	Brane	0-100	Potreba za održavanjem: (0-39 = samo nakon daljnjeg ispitivanja, 40-69 = samo ako je ekonomski izvedivo, 70-100 = nema potrebne radnje)
Lee i Aktan [23]	1997	Zgrade	1-4	Propadanje: (1 = nema, 2 = blago, 3 = umjereno, 4 = teško)
Lounis i sur. [65]	1998	Svi	1-7	Kategorija stanja: (1 = propalo, 2 = vrlo loše, 3 = loše, 4 = zadovoljavajuće, 5 = dobro, 6 = vrlo dobro, 7 = izvrsno)
WSDOT [46]	2000	Zgrade	1-5	Kategorija stanja: (1 - 2 = udovoljava trenutnim standardima, 3-4 = adekvatno, 4-5 = loše)
Teicholz i sur. [27]	2001	Zgrade	0.05-1.0	Kategorija stanja: (manje od 0,05 = dobro, 0,05 - 0,10 = zadovoljavajuće, više od 0,10 = loše)
NCES [44]	2003	Zgrade	1-8	Kategorija stanja: (1 = izvrsno, 2 = dobro, 3 = adekvatno, 4 = zadovoljavajuće, 5 = loše, 6 =

				neoperativno, 7 = hitno stanje, 8 = stanje izvanredne hitnosti)
DfES [66]	2003	Zgrade	A-D	Kategorija stanja: (razred A = dobro, razred B = zadovoljavajuće, razred C = slabo, razred D = loše)
Elhakeem i Hegazy [67]	2005	Zgrade	0-100	Propadanje: (0-20 = ne, 20-40 = blago, 40-60 = umjereno, 60-80 = teško i 80-100 = kritično)
Abbott i sur. [34]	2007	Bolničke zgrade	1-5	Kategorija stanja: (5 = vrlo dobro, 4 = dobro, 3 = zadovoljavajuće, 2 = loše, 1 = vrlo loše)
Ho i sur. [68]	2008	Stambene zgrade	0-1	Ocjena: (1 = zadovoljavajuće, 0.75 = iznad prosjeka, 0.5 = prihvatljivo, 0.25 = nedostatno, 0 = loše)
Pedro i sur. [55]	2008	Stambene zgrade	1-5	Nedostatak: (5 = manji, 4 = blagi, 3 = srednji, 2 = težak, 1 = kritičan)
Straub [54]	2009	Stambene zgrade	1-6	Kategorija stanja: (6 = vrlo loše, 5 = loše, 4 = slabo, 3 = zadovoljavajuće, 2 = dobro, 1 = izvrsno)
Salim i Zahari [69]	2011	Uredske zgrade	1-5	Kategorija stanja: (1 = dobro, 2 = manji popravci, 3 = opće održavanje, 4 = srednji popravci i zamjena, 5 = veliki popravci i zamjena)
Eweda [70]	2012	Obrazovne zgrade	0-100 %	Kategorija stanja: (A (90-100 %) = izvrsno, B (75-89) = vrlo dobro, C (60-74) = dobro, D (40-59) = zadovoljavajuće, E (20-39) = loše, F (0-19) = otkazivanje)
Adcock i Wilson [71]	2016	Stambene zgrade	A-J	Ocjena opasnosti: (A = 5000 i više, B = 2000-4999, C = 1000-1999, D = 500-999, E = 200-499, F = 100-199, G = 50-99, H = 20-49, I = 10-19, J = 9 ili manje)
Mohamed i Marzouk [41]	2021	Zgrade	0-100	Kategorija stanja: (0-40 = potpuno propadanje, 40-60 = loša kvaliteta, 60-75 = imperijalna kvaliteta, 75-85 = dobra kvaliteta, 85-92 = prihvatljiva kvaliteta, 92-99 = izvrsna kvaliteta, 99-100 = uzorna kvaliteta)

Piaia i sur. [72]	2021	Zgrade	1-6	Kategorija stanja: (1 = vrlo dobro, 2 = dobro, 3 = prihvatljivo, 4 = granično, 5 = loše, 6 = vrlo loše)
----------------------	------	--------	-----	---

Pitt je u istraživanju komentirao kako potreba za održavanjem često premašuje planirani budžet. Istaknuo je da se često navodi kao problem to što su kategorije korištene u ispitivanju stanja pregrube da bi rezultirale racionalnim programom održavanja. Autor navodi da je očito rješenje povećati broj kategorija, no kao i kod većine očitih rješenja, postoje nedostaci. Jedan nedostatak je taj što se sugerira da ljudi imaju poteškoća u razlikovanju više od šest ili sedam kategorija te stoga, ako se koristi više kategorija od tog broja, moraju postojati sumnje u pouzdanost i dosljednost podataka. Drugi nedostatak je da će čak i s dvostruko više kategorija i dalje postojati teškoće u podudaranju potrebe i proračuna, posebno kod graničnih vrijednosti. Osim toga, većina sustava ocjenjivanja stanja razvijena je za ručno sortiranje gdje je logistički vrlo teško rukovati velikim brojem kategorija [73].

2.4. Prethodna istraživanja o procjeni stanja zgrada

Langevine je razvio metodologiju za procjenu stanja komponenata zgrade tako da je istraživao proporcionalni značaj svake komponente zgrade u hijerarhijskoj strukturi na svakoj razini kroz temeljite inspekcije razvijene na najnižoj razini hijerarhijske strukture zgrade i upotrebom procesa konsolidacije za procjenu stanja zgrade. Formulirani model koji je temeljen na analitičkom hijerarhijskom procesu (engl. *Analytic Hierarchy Process* (AHP)) može odrediti relativne faktore težine za sustave i komponente zgrada s visokom točnošću, a dodijeljene težine su se koristile s vrijednostima indeksa stanja (engl. *Condition Index* (CI)) komponenata zgrade za procjenu CI sustava i zgrada s pomoću pristupa "roll-up". Autori navode da je model dovoljno fleksibilan da može prilagoditi revalorizaciju težina sustava i komponenata čak i među zgradama iste vrste [74].

Langevine, Allouche i AbouRizk razvili su sustav za donošenje odluka o održavanju zgrada (engl. *Building Maintenance Decision Support System* (BMDSS)) s funkcijom praćenja i modeliranja propadanja sustava i komponenata zgrada, za prognoziranje preostalog vijeka trajanja komponenata te za postavljanje prioriteta sustava i komponenata zgrada. Sustav koristi detaljne inspekcije provedene na najnižoj razini hijerarhije zgrade i primjenjuje postupak združivanja kako bi se odredila ocjena stanja zgrade. Nadalje, BMDSS također pruža okvir za postavljanje prioriteta u projektima održavanja, obnove i zamjene na temelju financijske analize i alata za optimizaciju koji vode do maksimalnih koristi unutar okvira ograničenog financijskog proračuna. Okvirni model BMDSS-a okuplja raznolik niz alata koji pomažu upraviteljima imovine da analiziraju svoje trenutačne prakse upravljanja održavanjem i donose pravilne

odluke u vezi sa svojom imovinom te se veći dio potrebnih informacija o troškovima može dobiti iz računalnih sustava za upravljanje održavanjem koji se koriste u javnim agencijama u Kanadi [75].

Abbott i sur. predložili su sustav ocjenjivanja bojama u pet stupnjeva za bolničke zgrade u Južnoj Africi radi procjene proračuna za održavanje. Svaka boja predstavlja stanje ocjenjivanja od 1 do 5, pri čemu se ocjena 5 predstavlja crvenom bojom kao vrlo dobro stanje, a ocjena 1 predstavlja plavom bojom kao vrlo loše stanje, dok se srednje ocjene 4, 3 i 2 predstavljaju cijan plavom, zelenom i žutom bojom kao dobro, zadovoljavajuće i loše stanje, redom. U njihovom modelu ocjenjivanje stanja provodi se na razini elementa ili komponente, a odgovarajuće radnje održavanja relevantne za ocjene stanja izračunavaju se s troškovima održavanja, popravka i zamjene u tabličnom obliku. Elementi svake zgrade agregiraju se kako bi se utvrdio proračun na razini zgrade, a zatim se dalje agregiraju na razini objekta. Korištenjem njihovog sustava ocjenjivanja stanja bojama, promjene u ocjenama stanja u kasnijim procjenama lako se mogu identificirati. Prema Abbottu i sur., ocjenjivanje stanja bojama čini izvještaje o ocjeni jednostavnijim za korištenje korisnicima koji nisu tehnički stručnjaci, olakšavajući im pristup informacijama. Autori ističu važnost redovitog i dosljednog ocjenjivanja stanja kako bi se osigurala održivost te potrebu za optimizacijom primjene podataka iz ocjenjivanja zbog visokih troškova povezanih s fizičkim posjetima prilikom provođenja ocjenjivanja stanja [34].

Pedro i sur. predstavili su metodu ocjenjivanja stanja zgrada u Portugalu, koja se procjenjuje dijeljenjem cijele zgrade na elemente, a nedostaci u elementu ocjenjuju se na temelju predefiniраниh kriterija. U ovom modelu ocjenjivanja stanja razina nedostataka u različitim elementima bilježi se u kontrolnom popisu, a zatim se agregira formulom kako bi se dobila numerička ocjena. Taj kontrolni popis podijeljen je na osam odjeljaka: identifikacija zgrade prema lokaciji, adresa, karakterizacija zgrade prema broju jedinica, etaža, vrsta uporabe, nedostaci u funkcionalnim elementima, indeks nedostataka, opis ozbiljnih i kritičnih nedostataka, evaluacija, promatranja, podaci o ocjenjivaču i koeficijent održavanja. Funkcionalni elementi sastoje se od podskupina i podijeljeni su u tri grupe: cijela zgrada, zajednički dijelovi između više jedinica i sama jedinica, a ocjenska skala sastoji se od pet stupnjeva temeljenih na razini nedostataka, pri čemu se 5 bodova dodjeljuje za manje nedostatke, 1 bod za kritične, te 4, 3 i 2 boda za blage, srednje i teške, redom. Ocjena svakog elementa izračunava se kao produkt broja bodova povezanih s razinom nedostatka i koeficijenta težine koji varira od 1 (manja važnost) do 6 (veća važnost). Indeks nedostataka izračunava se kao zbroj ukupnih bodova za primjenjive funkcionalne elemente podijeljenih zbrojem ukupnih težina primjenjivih funkcionalnih elemenata. Dodatno je kategoriziran u pet vrsta stanja, varirajući od vrlo lošeg, lošeg, srednjeg, dobrog do izvrsnog stanja. Indeks koji se nalazi između 4,5 i 5 smatra se izvrsnim, dok se između 1 i 1,5 smatra vrlo lošim stanjem. Stanje koje odredi ocjenjivač pretvara se u koeficijent održavanja uzimajući u obzir moguće održavanje i popravke koje su

obavili vlasnici i najmoprimci. Primarni cilj modela ocjenjivanja stanja opisanog od strane autora je određivanje maksimalne vrijednosti najamnine u Portugalu, međutim, može se koristiti i u svrhe održavanja, ali zahtijevalo bi detaljniju inspekciju i odgovarajuće veće troškove. Autori ističu da je postupak ocjenjivanja izuzetno subjektivan i ovisi o kompetenciji ocjenjivača [55].

Straub te Kuijper i Bezemer analizirali su uporabu ocjenjivanja stanja zgrada prema nizozemskom standardu NEN 2767 [54, 76]. U ovom modelu ocjenjivanja stanja zgrada, stanje se može izraziti na ljestvici od 1 do 6. Ocjenjivanje se temelji na otkrivanju nedostataka u funkcionalnim elementima i na definiciji njihove važnosti, obima i intenziteta [54]. Inspektor na terenu mora odrediti nedostatke sa standardiziranog popisa nedostataka i ocijeniti ih prema skali i intenzitetu svakog [76]. Ocjenjivanje nedostatka je prva faza, a zatim slijedi klasifikacija važnosti, nakon čega slijedi identifikacija intenziteta i obima.

Nizozemski standard klasificira važnost/ozbiljnost nedostataka na tri razine [54, 76]:

- Manji nedostaci: Nema utjecaja na funkcioniranje zgrade ili dijela zgrade, primjerice, nedostaci u završnoj obradi ili oštećenja na zidu.
- Ozbiljni nedostaci: Ozbiljni nedostaci postupno oštećuju performanse građevinskih elemenata i dovode do degradacije zgrade ili dijela zgrade, obično bez ometanja izravnog funkcioniranja elementa ili zgrade, primjerice, oštećenje površine materijala ili starenje elemenata.
- Kritični nedostaci: Kritični nedostaci klasificiraju se kao funkcionalni nedostaci i nedostaci koji ugrožavaju strukturu zgrade, poput sigurnosti, stabilnosti i izobličenja. Funkcionalni nedostaci su oni koji su povezani s otkazivanjem elementa.

Nizozemski standard također klasificira intenzitet nedostataka koji utječu na stanje građevinskih elemenata u tri klase, odnosno intenzitet 1, 2 i 3, kao niski, srednji i visoki intenzitet, redom. Intenzitet klase 1, nedostaci su niskog intenziteta, jedva su vidljivi, dok su klase 2 progresivni, a klase 3 visokog intenziteta i ne mogu dalje napredovati [54].

Salim i Zahari predložili su integrirani sustav pokazatelja za zgrade (engl. *Integrated Building Indicator System* (IBIS)), ocjenjivački sustav za ocjenjivanje postojećeg stanja zgrada i određivanje troškova popravka građevinskih nedostataka prije popravka ili obnove uredskih zgrada u Maleziji. IBIS model uzima u obzir sljedeće faktore: vrstu zgrade, namjenu zgrade, bruto površinu, broj nedostataka, trošak popravka svakog nedostatka i ukupni trošak popravka zgrade. Formula koja se koristi u IBIS-u je produkt omjera između troška ukupnih nedostataka i bruto površine s konstantom koja daje ocjenu. U IBIS modelu pet ocjena stanja zgrade temelji se na trošku svakog nedostatka, koji varira od ocjene 1-5, pri

čemu ocjena 5 označava najniži trošak svakog nedostatka, dok ocjena 1 označava najviši trošak. Najviša ocjena 5 sadržavat će manje nedostatke u zgradi, dok će najniža ocjena sadržavati ozbiljne nedostatke s najvišim troškom popravka [69].

Dejaco i sur. predložili su dva tipa ocjena kao ključne pokazatelje uspješnosti (engl. *Key Performance Indicators* (KPI)) nazvana tehnički indeks i indeks dokumenata za ocjenjivanje stanja zgrada u Italiji. U njihovom prijedlogu, tehnički indeks služi za ocjenjivanje stanja zgrade s obzirom na starenje i nepravilnosti njezinih komponenata, dok indeks dokumenata opisuje dostupnost dokumenata zgrade uzimajući u obzir zakonske zahtjeve. U ovom modelu ocjenjivanja tehnički indeks sastoji se od tri podindeksa. Prva dva uspoređuju stvarni vijek trajanja svake komponente s njezinom referentnom vrijednošću, koja se naziva indeks vijeka trajanja (D+ i D-) dok treći indeks procjenjuje anomalije na svakoj komponenti zgrade, a naziva se indeks degradacije (A). Svaka ocjena za dokument ocjenjuje se kao produkt njegove važnosti, težine i prisutnosti, pri čemu je ocjena 1 ako je dokument dostupan i 0 ako nije. Agregirajući svaku ocjenu za dokument, indeks dokumenata izračunava se kao ponderirani omjer između broja dostupnih dokumenata i broja dokumenata koji bi trebali biti dostupni za određenu zgradu [77]. Nastavno na navedeno istraživanje, Dejaco i sur. utvrdili su da je jedan KPI lakše razumljiv, što vodi do kombiniranog indeksa zgrade koji se izračunava kao jednostavna prosječna vrijednost tehničkog indeksa i indeksa dokumenata te su oba indeksa uvijek prikazana zajedno [78]. Dostupnost dokumenata za postojeće zgrade utječe na terensku inspekciju tijekom procesa ocjenjivanja stanja, bez obzira na korištene tehnike ili usvojene metodologije. Autori smatraju da indeks dostupnosti dokumenata može biti koristan za usklađenost s lokalnim građevinskim propisima, kao i za detaljniju inspekciju.

Grussing i sur. predstavili su model za korištenje podataka o pregledu građevinskih komponenti u svrhu konstruiranja prijelazne matrice potrebne za predviđanje stanja, pouzdanosti i očekivanog vijeka trajanja koristeći Markovljev proces. Autori ističu da će izravna primjena novog Markovljevog modela podržati poboljšani odabir aktivnosti na građevinskim komponentama i optimizaciju ukupnih troškova, kako za pojedinačne komponente, tako i za optimizaciju troškova cijele zgrade. Također se može koristiti kako bi se podržao proces procjene vrijednosti inspekcije komponenti i određivanja optimalnog vremena i plana inspekcija, uzimajući u obzir stanja i pouzdanost iz Markovljevog modela. Osim toga, navodi se da model pruža način korištenja informacija o procjeni stanja s promjenjivim vremenskim intervalima kako bi podržao razvoj prijelaznih matrica te rezultira mjerom pouzdanosti koja se odnosi na vjerojatnost kvara komponente, pružajući potrebnu mjeru za upravljanje rizikom. Autori naglašavaju da će, kako budu dostupni dodatni podaci, buduća istraživanja razmotriti daljnje podjele prijelaznih matrica prema geografskim regijama kako bi se obuhvatila okolišna varijabilnost propadanja. Također,

kako bi se dovršila veza između procjena stanja komponenata i računalnih sustava za upravljanje održavanjem koji prate izvođenje radnih aktivnosti, moći će se razviti matrice prijelaza popravaka temeljene na određenim vrstama popravaka. Buduća istraživanja će dodatno unaprijediti sposobnosti predviđanja stanja i pouzdanosti komponenata te na kraju poboljšati procese planiranja radova [79].

Mohd Noor i sur. opisali su provedbu procjene stanja zgrade na zgradi kulturne baštine temeljenu na održivosti, sigurnosti i funkcionalnosti konstrukcijskih i arhitektonskih elemenata kao i održivosti građevinskih materijala. Ovo istraživanje određuje rangiranje svakog nedostatka u odnosu na njegovo stanje i potrebu za održavanjem koristeći sustav ocjenjivanja putem sveobuhvatnog vizualnog pregleda i detaljnih bilješki za svaki trenutni nedostatak i nedostatke. Što se tiče materijala, provedena je spektroskopija energijskih disperzija rendgenskog zračenja na uzorcima elemenata s ciljem identificiranja kemijskog sastava građevinskih materijala koji se koriste kako bi se očuvala izvornost tijekom radova na obnovi i održavanju [80].

Piaia i sur. predstavili su okvir koji koristi postojeće informacije iz informacijskog modeliranja građevina (engl. *Building Information Modeling* (BIM)) kako bi ubrzali i poboljšali učinkovitost inspekcija zgrada i to tako da se planiranje očuvanja i održavanja može prilagoditi i optimizirati u skladu s različitim zahtjevima. Autori ističu da njihovo rješenje omogućuje ne samo profesionalnu procjenu stanja, već i optimizaciju planiranja očuvanja i održavanja prema različitim ambicijama i potrebama. Naglašava se da podržavaju održivu konzervaciju i održavanje zgrada kulturne baštine putem softverske platforme za procjenu stanja na licu mjesta i upravljanje sredstvima s već uspostavljenom platformom za BIM, a alat za upravljanje sredstvima kulturne baštine smatra se prije svega korisnim u okviru procesa donošenja odluka o obnovi i očuvanju te održavanju povijesnih zgrada [72].

Kako bi se smanjio trenutni jaz i neusklađenost u procesu procjene te olakšao rad građevinskih inspektora, Lupășteanu i sur. razvili su novi model procjene stanja temeljen na općim smjernicama iz rumunjske nacionalne norme. Metoda poznata kao PEST (rumunjska kratica za Metodu procjene tehničkog stanja) uključuje provođenje terenskih istraživanja i korištenje metodologije za procjenu oštećenja i određivanje razreda degradacije zgrade. Šezdeset i dvije zgrade različitih tipova, starosti i sustava gradnje podvrgnute su procjenama stanja kako bi se provjerila učinkovitost i primjenjivost modela. Autori su izjavili da su terenska istraživanja provedena metodično, brzo i s izvrsnim rezultatima koristeći predloženi pristup. Kao glavnu prednost autori ističu primjenjivost metode na različite vrste zgrada, budući da standardizirana nacionalna procedura nije prisutna [81].

Inovativni okvir za procjenu stanja, koji koristi nekoliko pristupa umjetne inteligencije (engl. *Artificial Intelligence* (AI)) prikladnih za analizu podataka o stanju različitih građevinskih komponenti, predložili su

Ahmedi sur. Okvir je primijenjen na podatkovni skup koji obuhvaća više od 2000 zahtjeva za održavanjem krovova i sustava grijanja, ventilacije i klimatizacije (engl. *Heating, Ventilation and Air Conditioning* (HVAC)) iz portfelja od 600 vila. Konvolucijske neuronske mreže korištene su za analizu fotografija oštećenja krova, dok je unaprijeđeno rudarenje podataka iskorišteno za prikupljanje tekstualnih informacija o HVAC sustavima kako bi se zadovoljile njihove različite potrebe. Za popravak 203 HVAC sustava identificirani su radni paketi s degradiranim komponentama i izrađen je raspored za 60 dana. Autori naglašavaju da AI može značajno pomoći upravljanju objektima u procjeni stanja, planiranju rehabilitacije i raspodjeli resursa, što ističu kao glavnu snagu modela [82].

Bucoń i Czarnigowska razvili su metodologiju za pomoć u planiranju modernizacije stambenih zgrada, od procjene stanja do određivanja idealnog opsega renovacije. Višekriterijska procjena stanja zgrade sastojala se od četiri faze: Odabir kriterija (tehničkih, kulturnih, društvenih, ekonomskih i ekoloških) za procjenu stanja zgrade; Korištenje AHP pristupa za određivanje težinskih vrijednosti odabranih kriterija; Procjena pomoću sustava ocjenjivanja s 5 razina, pri čemu 5 bodova označava vrlo dobro (BD), 4 boda dobro (D), 3 boda prosječno (S), 2 boda loše (Z), a 1 bod vrlo loše (BZ); Procjena stanja zgrade koristeći višekriterijski pristup. Prema autorima, glavna prednost ovog istraživanja je što razvijeni model pruža menadžerima koristan i prilagodljiv alat za upotrebu tijekom faze održavanja stambenih zgrada. Glavni nedostatak modela je njegova deterministička priroda, koja zanemaruje promjene uzrokovane starenjem zgrade te varijacije u unaprijed procijenjenim troškovima popravaka [83].

U tablici 3 nalazi se sažeti prikaz prethodnih istraživanja o procjeni stanja zgrada

Tablica 3 Sažeti prikaz prethodnih istraživanja o procjeni stanja zgrada

Izvor	Godina	Namjena zgrada	Kriteriji procjene	Svrha ocjene	Metoda prikupljanja podataka	Metoda obrade podataka i korišteni alati
Langevine, Allouche i AbouRizk [74]	2006	Sve	Proizvoljni	Donošenje odluka	Vizualni pregled	Softver i Markovljev model
Abbott i sur. [34]	2007	Bolničke	Obnova i troškovi zamjene	Raspodjela proračuna za održavanje	Vizualni pregled	Obrazac i Markovljev model
Ho i sur. [68]	2008	Stambene	Opasnosti za sigurnost i zdravlje	Zdravlje zgrade i sigurnost	Vizualni pregled i	Obrazac i AHP

Begić Juričić, Hana, 2025, *Razvoj sustava procjene stanja školskih zgrada i modela procjene potrošnje energije, energenata i vode*. Doktorska disertacija. Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek.

					anketni upitnik	
Pedro i sur. [55]	2008	Stambene	Na temelju nedostataka zgrade	Za odlučivanje o visini najamnine	Vizualni pregled	Obrazac i internetska stranica
Straub [54]	2009	Stambene	Na temelju nedostataka zgrade	Troškovi održavanja	Vizualni pregled	Obrazac
Salim i Zahari [69]	2011	Uredske	Starost zgrade, nedostaci i troškovi popravaka	Popravak i održavanje	Vizualni pregled	Obrazac
Wilson [71]	2016	Stambene	Vjerojatnost opasnosti za štetu zdravlju i sigurnosti	Procjena rizika sigurnosti	Vizualni pregled	Računalni softver
Dejaco i sur. [77]	2014	Stambene	Starenje zgrade i dostupnost dokumenata	Upravljanje imovinom	Vizualni pregled	Računalni softver
Grussing [79]	2016	Sve	Vrsta komponente i starost, vrsta i starost zgrade kojoj pripada	Upravljanje imovinom	Baza podataka prošlih inspekcija	Računalni softver i Markovljev model
Mohd Noor i sur. [80]	2019	Kulturna baština	Funkcionalnost, sigurnost, održivost i održavanje	Utvrđivanje prioriteta održavanja	Vizualni pregled	Obrazac i spektroskopija
Piaia i sur. [72]	2020	Kulturna baština	Informacije iz BIM modela	Poboljšanje učinkovitosti inspekcije	Baza podataka	Računalni softver
Faqih i Zayed [84]	2021	Sve	Na temelju nedostataka zgrade	Identificiranje nedostataka i ocjena zdravlja zgrade	Anketni upitnici	Zamagljeni skupovi, ANP i dokazno rasuđivanje
Lupășteanu i sur. [81]	2022	Razne	Ocjena oštećenja i utvrđivanje	Pomoć inspektorima	Vizualni pregled	Obrazac, PEST metoda

			razreda degradacije			
Ahmed i sur. [82]	2023	Stambene	Informacije o stanju komponenti	Planiranje i alokacija resursa	Prikupljanje podataka o HVAC sustavima, slike krovova	CNN, rudarenje podataka
Bucoń i Czarnigowska [83]	2024	Stambene	Tehnički, kulturni, društveni, ekonomski i ekološki kriteriji	Pomoć u planiranju modernizacije i renovacije	Vizualni pregled	AHP

2.5. Prethodna istraživanja o procjeni stanja obrazovnih zgrada

Ahluwalia je predstavila novi okvir koji čini proces procjene stanja zgrada strukturiranim, manje vremenski zahtjevnim, manje subjektivnim i manje skupim. Predloženi okvir sastoji se od tri glavne komponente [46]:

- Predviđanje stanja i planiranje inspekcija (na temelju dostupnih zapisa o održavanju) kako bi se istaknuli dijelovi koji najviše trebaju biti proučavani od strane iskusnih ocjenjivača.
- Sustav vizualnog vodiča u kojem slikovna baza podataka podržava vizualnu inspekciju komponenata zgrada.
- Inspekcija temeljena na lokaciji sa standardiziranom hijerarhijom zgrada.

Autorica ističe da je ovaj okvir usmjeren na automatizaciju procesa kako bi se posebno prilagodio velikim organizacijama koje imaju ograničene resurse u vezi s procjenom stanja i upravljanjem kapitalnim sredstvima te da može značajno poboljšati učinkovitost procesa procjene stanja objekata i smanjiti troškove. Razvoj sustava uključivao je analizu podataka unazad dvije godine o reaktivnom održavanju uzorka od 88 škola iz Toronta. Na temelju te analize, prepoznati su izazovi u procesu zamjene kapitala, te je predložen jedinstveni sustav indikacija stanja temeljen na dostupnim podacima o reaktivnom održavanju kako bi se smanjila učestalost inspekcija i prioriteta zadataka inspekcije među dostupnim resursima. Nakon što su razvijene tri komponente okvira, kombinirane su u integrirani prototip koji su testirali zaposlenici škola. Prototip s intuitivnim sučeljem i nezahtjevnom obukom za njegovo korištenje dobro je prihvaćen i pokazao je prednosti u kontekstu: pružanja učinkovitog i automatiziranog pristupa prikupljanju terenskih podataka, uključujući slike; uključivanja digitalnih nacrtā kao osnove za pohranu i

pregled podataka; korištenja podataka o održavanju kako bi se minimizirao napor inspekcije i prioritizirali zadaci; uštede troškova skupih vanjskih izvođača inspekcije omogućavajući zadatke koje može obaviti mali interni tim; olakšavanja boljeg rješenja (veće raznolikosti) prioriteta preko podataka [46].

Che-Ani i sur. predstavili su novu metodu procjenu stanja zgrade i ocjenu ozbiljnosti svakog identificiranog nedostatka. Ova dva kriterija za ocjenu zatim se množe kako bi se dobila ocjena zgrade, koja se naziva Matricom Protokola za procjenu stanja (engl. *Condition Survey Protocol* (CSP)) 1. Autori navode da, umjesto detaljnog opisa nedostataka zgrade, matrica zahtijeva sažeta objašnjenja o identificiranim nedostacima, čime se štedi vrijeme na licu mjesta tijekom pregleda zgrade. Sustav prikuplja dva skupa podataka, točnije stanje zgrade i ozbiljnost nedostataka zgrade, koji se mogu analizirati kako bi se dobila ocjena ukupnog stanja zgrade. Matrica je također prikladna za sve vrste zgrada jer se unos podataka temelji na procjenama stanja i oštećenja te je moguće format matrice prilagoditi bilo kojem stanju pregleda. Glavni ciljevi matrice CSP1 su sljedeći [85]:

- i) Omogućiti prikupljanje podataka u najkraćem mogućem vremenu izbjegavajući opise u tekstu i detaljne zapise tijekom terenskog pregleda.
- ii) Zabilježiti postojeće nedostatke zgrade, glavni izvor podataka, procjenjujući stanje i dodjeljujući prioritet svakom zabilježenom nedostatku.
- iii) Dobiti ukupnu ocjenu stanja zgrade.
- iv) Koristiti numeričku ocjenu dobivenu iz ispitivanja za provođenje statističke analize.

Podaci potrebni za CSP1 matricu uključuju ocjene stanja i prioritete. Svaka numerička ocjena (od 1 do 5) popraćena je vrijednošću skale i opisom koji ovise o standardima održavanja zgrade koja se ocjenjuje. Svaki zabilježen nedostatak dodjeljuje se ocjeni stanja i prioritetnoj ocjeni. Svaka ocjena zatim se množi kako bi se odredila ukupna ocjena za svaki nedostatak. Ukupna ocjena zatim se uspoređuje s matricom gdje se ocjene kreću od 1 do 20. Zatim se primjenjuje boja (zelena, žuta ili crvena) kako bi se označila ocjena u svakom od 3 parametra: planirano održavanje (ocjena 1 do 4), praćenje stanja (ocjena 5 do 12) i potrebna ozbiljna pažnja (ocjena 13 do 20). Nakon što se ocijeni svaki nedostatak, moguće je izračunati ukupnu ocjenu zgrade. Ocjena svakog nedostatka se zbroji i podijeli s ukupnim brojem nedostataka kako bi se dobila ukupna ocjena zgrade čije se stanje zatim ocjenjuje kao dobro, zadovoljavajuće ili loše, prema ocjeni [85].

CSP1 matrica primijenjena je u studiji slučaja za procjenu stanja pametne škole u Maleziji gdje se pokazala pouzdanom i praktičnom metodom ocjenjivanja. Međutim, autori ističu da CSP1 matrica zahtijeva daljnju primjenu sa svrhom utvrđivanja je li prikladna za inspekcije srednjih i velikih zgrada.

Osim toga, navode da nije prikladna za slučajeve gdje su potrebni detaljniji opisi nedostataka, posebno za pripremu izvješća o pregledu zgrade [86].

Nadalje, CSP1 matrica primijenjena je na javne osnovne škole u Maleziji gdje su autori analizirali povezanost između starosti škole i njezinih nedostataka. Analiza provedena na 24 škole otkrila je ukupno 4725 nedostataka, a ukupna ocjena iznosila je 9,71, što se smatra prihvatljivim stanjem uz potrebno praćenje stanja. Rezultati istraživanja su potvrdili da je stanje zgrade usko povezano sa starošću zgrade i podržava teoriju da starija zgrada ima više nedostataka od nove [87].

Eweda i sur. predložili su integrirani model za ocjenjivanje stanja koji uzima u obzir fizičke i okolišne aspekte za ocjenjivanje obrazovnih zgrada u Kanadi. Glavna svrha ovog modela bila je pomoći vlasnicima i upraviteljima zgrada u procesu ocjenjivanja stanja radi upravljanja imovinom. Autori su koristili "prostor" u zgradi kao glavni element evaluacije. Analitički mrežni proces (engl. *Analytical Network Process* (ANP)) i AHP korišteni su na podacima prikupljenim od strane stručnjaka kako bi se dodijelile relativne težine u modelu. Višekriterijska teorija korisnosti (engl. *Multiattribute Utility Theory* (MAUT)) korištena je za izračunavanje fizičkih i okolišnih uvjeta svakog prostora, a tehnikom K-srednjih vrijednosti izračunava se integrirano stanje svakog prostora. Glavne sastavnice ovog istraživanja bile su: prostori unutar zgrade i njihovo rangiranje, fizička i okolišna procjena prostora te integrirano stanje prostora i cijele zgrade. Ovo istraživanje koristi indeks stanja koji se kreće od 0-100 i odgovarajuće abecedne ocjene od A-F. Indeks stanja od 90-100 ocjenjuje se kao A, što predstavlja izvrsno stanje bez nedostataka, dok se indeks stanja od 0-19 ocjenjuje kao F, što označava potpuni neuspjeh. Intermedijarna stanja ocjenjuju se kao vrlo dobro, dobro, zadovoljavajuće i loše za indekse stanja koji se kreću od 75-89, 60-74, 40-59, 20-39, redom [88].

Nastavno na navedeno istraživanje, Eweda je predstavio integrirani model procjene stanja za obrazovne zgrade u Kanadi koji uzima u obzir fizičke i okolišne uvjete zgrada. Budući da su zgrade sastavljene od prostora, predloženi model koristi "prostor" kao glavni element procjene. MAUT se koristi za izračun fizičkih i okolišnih uvjeta svakog prostora, a provodi se i grupiranje po srednjim vrijednostima kako bi se izračunalo integrirano stanje svakog prostora. Podaci su se prikupljali od stručnjaka putem upitnika radi dodjeljivanja relativnih težina atributima modela koristeći tehnike ANP i AHP. Predložena metodologija nadograđuje upotrebu BIM modela kako bi se mogao koristiti kao platforma i napredan alat za pohranu, razmjenu i prijenos ulaznih podataka za procjenu, kao i za sudjelovanje u procesu procjene. Ova integracija omogućava da se BIM model koristi kao izvor podataka i pruža potrebne grafičke prikaze. Model je implementiran i testiran koristeći podatke prikupljene od stručnjaka i mjerenja na terenu izvedenih u obrazovnoj zgradi u Montrealu. Autor ističe da je model validiran od strane stručnjaka koji

rade u području upravljanja objektima koji su ustanovili da ima dobar potencijal [70]. Na temelju modela razvijenog u doktorskom radu nastavljena su istraživanja autora i suradnika u radovima [5] i [89].

ElSamadony i sur. predstavili su model za obrazovne zgrade u Egiptu koji uključuje podatke o održavanju kako bi potaknuli pouzdanu pripremu za inspekciju i ubrzali procjenu stanja međusobno povezanih komponenata zgrade [90]. Predloženi model minimizira terensko praćenje uključivanjem modela degradacije koji koristi tehnike neuronskih mreža kako bi predvidio različite pristupe popravku u planiranom vremenu. Podaci koji su korišteni za treniranje, testiranje i validaciju mreže uključuju: izračunate podatke o održavanju, prosječnu iskorištenost škole, vrstu škole, geografske podatke i starost, što je najvažniji faktor koji utječe na izračun predviđanja propadanja. Za provođenje takve analize, podaci o popravcima i reaktivnom održavanju za uzorak od 25 škola dobiveni su od Egipatske agencije za obrazovne zgrade. Dva tipa podataka za zadnja tri plana popravaka prikupljena su iz škola [90]:

- (1) opći podaci koji su uključivali informacije o vrsti škole (osnovna ili srednja), godini izgradnje, površini (u četvornim metrima), kapacitetu učionica i lokaciji te
- (2) specifični podaci koji su sadržavali podatke o prethodnim popravcima, uključujući opis radova, kod, količinu popravka, jediničnu cijenu i ukupan trošak popravka.

Autori naglašavaju da je prikupljanje specifičnih podataka bio zadatak velikih razmjera zbog veličine i povjerljivosti podataka te vjeruju da bi ovakav pristup mogao biti koristan upraviteljima zgrada prilikom odabira najboljih opcija u vezi s održavanjem, popravkom i obnovom obrazovnih zgrada [90].

Marzouk i Awad razvili su model za procjenu stanja škola primjenjujući AHP, a sugeriraju da bi ti rezultati mogli biti korisni upravama škola kao komponenta sustava za podršku odlučivanju. Ovaj model sadrži četiri razine procjene učinka koje se bave programom, objektom, paketom i elementom. AHP-fuzzy model se gradi koristeći jezične izraze kako bi se predstavilo stanje imovine. Predloženi model generira standardne indekse za tri razine (element, paket i objekt) koji se agregiraju kako bi se pružila realna procjena stanja za grupu objekata (program). Objekt se sastoji od određenog broja fizičkih prostora, a svaki prostor ima svoju specifičnu funkciju, lokaciju i tip. Svaki prostor sadrži određeni broj elemenata koji su dodijeljeni za inspekciju; to mogu biti prozori, vrata, podovi, itd. Za evaluaciju ovog modela prikazana je studija slučaja s podacima iz 21 škole u guverneratu Giza u Egiptu [91].

Proces za uspostavu modela izveden je u pet glavnih faza [91]:

- postavljanje skupa težinskih faktora među različitim elementima,

- prikupljanje podataka,
- pokretanje fuzzy modela za generiranje ocjena indeksa stanja za element i paket,
- generiranje indeksa stanja za objekte i program i
- predlaganje mjera.

Autori smatraju da bi rezultati mogli biti korišteni od strane uprave kao dio sustava podrške odlučivanju te predlažu daljnje razvijanje modela kako bi se uključilo više elemenata poput vanjskih ograda, svjetlosnih stupova i cesta te istraživanje utjecaja okoline na škole [91].

Sadick i Issa detaljno su istražili razvoj i usvajanje alata za ocjenu stanja na razini prostora zgrade kako bi procijenili utjecaj fizičkog stanja komponenata zgrade na kvalitetu unutarnjeg okoliša, posebice u školskim zgradama. U istraživanju su promatrane 52 učionice, bilo u novim, obnovljenim ili neobnovljenim školama. Rezultati informacija o ocjeni stanja na razini prostora pokazali su da najveći postotak statistički značajnih razlika postoji između novih i neobnovljenih škola, dok je najmanji između obnovljenih i neobnovljenih škola. Utvrđeno je da je najjača i statistički značajna korelacija ($r = 0,86$) bila između rezultata ocjene stanja na razini prostora za glavni omotač zgrade i relativne vlažnosti samo u školama koje nisu obnovljene. Autori ističu da je ova povezanost logična jer će povećanje nedostataka u ovojnici zgrade razine kao što su pukotine /rupice/odvajanja vjerojatno povećati relativnu vlažnost, čineći da se temperatura zraka čini toplijom [92].

Linggar, Aminullah i Triwiyono razvili su model za procjenu stanja temeljen na ključnim komponentama koje čine studentske smještajne objekte u Indoneziji. Pristup ocjenjivanju zgrade segmentira se prema katovima (prizemlje, 1. kat, 2. kat i slično) gdje je svaki kat ključni segment čija se kvaliteta ocjenjuje prema njegovim individualnim karakteristikama. Za određivanje relativne važnosti svake komponente koristili su se upitnici poslani stručnjacima i analiza potvrđnih faktora. Model je primijenjen na studiji slučaja studentskog doma Sveučilišta Gadjah Mada, smještenog u Yogyakarta. Prema autorima, rezultati ovog istraživanja pružaju smjernice vlasnicima i upraviteljima smještajnih objekata kako bi bolje planirali i provodili strategije obnove i održavanja studentskih domova [93].

Mohamed i Marzouk predstavili su novi okvir za ocjenu fizičkog stanja postojećih obrazovnih objekata koristeći pristup koji uključuje prediktivni model umjetne neuronske mreže (engl. *Artificial Neural Network* (ANN)) i strukturalni model jednadžbe (engl. *Structural Equation Modeling* (SEM)). ANN prediktivni model ima za cilj predviđati buduće ocjene stanja za svaku komponentu objekta u različitim prostorima zgrade. Istovremeno, SEM određuje proporcionalne težine komponenata zgrade. Podaci korišteni u ovom istraživanju prikupljeni su s Fakulteta na Kairskom sveučilištu u Egiptu, a baza podataka koja se odnosi na praćenje stanja sadrži podatke prikupljene tijekom zadnjih dostupnih pet godina koji

su bilježeni na temelju vizualnih opservacija inspektora. Kao osnovne ciljeve istraživanja autori navode prioritiziranje komponenata zgrade u svrhu održavanja te zabilježavanje potencijalnih učinaka različitih parametara koji utječu na stanje komponenata zgrade te predlažu njihovo postizanje putem četiri uzastopna modula: 1) modul za skeniranje u BIM; 2) modul za predviđanje procjene stanja; 3) modul za određivanje proporcionalne težine i 4) modul za procjenu ukupne vrijednosti prostora. Analizirali su se podaci o stanju šest različitih unutarnjih komponenata zgrada kako bi se predvidjelo njihovo buduće stanje, a to su: 1) drvene podne pločice; 2) stropne ploče od gipsa; 3) drvena vrata; 4) drveni prozori, 5) klima uređaji s izmjenjivačem topline; i 6) stolna računala. Rezultati studije slučaja potvrdili su primjenjivost predloženog modela u procesu donošenja odluka klijenata i upravitelja objekata u vezi sa zahtjevima za održavanjem, putem procjene stanja komponenata objekta. Kao smjernice za daljnja istraživanja autori navode da se predloženi model može proširiti uzimajući u obzir različite vrste zgrada te uzimajući u obzir različite izazove, razmatranja i pitanja. Osim toga, prognoza stanja može se dodatno poboljšati uzimanjem u obzir nesigurnosti i izazove povezane s propadanjem komponenata objekta tijekom njihovog životnog ciklusa [41].

Kejeh, Nwaogazie i Samuel razvili su matricu 3x3 za procjenu stanja održavanja obrazovnih i bolničkih zgrada. Model je razvijen analogno matrici protokola za procjenu stanja CSP 1 kao metoda procjene stanja zgrade. Matrica procjene održavanja zgrade koristila je dva parametra u ocjenjivanju – trenutno stanje zgrade i praksu upravljanja održavanjem koju je usvojila jedinica za održavanje. Prema autorima, praksa sustava upravljanja održavanjem sastoji se od četiri faktora odnosno pitanja vezana uz upravljanje održavanjem [94]:

- i) Ima li škola/ bolnica plan održavanja?
- ii) Ima li škola/bolnica bazu podataka u kojoj se bilježe aktivnosti održavanja?
- iii) Postoji li dobar sustav osiguranja kvalitete?
- iv) Upravljanje ljudskim resursima (adekvatno osoblje za održavanje).

Informacije o svakom od čimbenika korištenih za ocjenu stanja održavanja zgrade dobivene su korištenjem kontrolne liste. Ocjenjivač je fizički ocijenio svaku zgradu bilježeći jesu li navedeni čimbenici koji se koriste za ocjenu prakse sustava upravljanja održavanjem dostupni i funkcionalni. Kako bi se dobio rezultat, izračunata je prosječna ocjena za četiri čimbenika održavanja. Za trenutno stanje objekta korišteno je deset ključnih elemenata za ocjenu trenutnog stanja. Ocjena od 1 do 3 dodijeljena je svakom stanju na temelju trenutnog stanja određenog elementa. Zatim je izračunata prosječna ocjena za deset elemenata kako bi se dobio rezultat trenutnog stanja zgrade. Model je primijenjen za ocjenu stanja održavanja 14 javnih bolnica (općih bolnica) i dvije javne škole (tercijarnih ustanova) u Nigeriji [94].

Hassan i sur. predstavili su metodologiju za određivanje CI. Takav indeks mogao bi se dobiti na razini elementa i pomoću njega odrediti ukupno stanje zgrade. Metodologija je podržana modelom ANN sa svrhom predviđanja propadanja elementa. Korištena je ANN s tri sloja propagacije unatrag te je trenirana, testirana i uspoređena s metodom najmanjih kvadrata (engl. *Ordinary Least Squares* (OLS)) kako bi se potvrdila točnost predviđanja modela. Studija slučaja primijenjena je na skupinu unutarnjih i vanjskih drvenih vrata obrazovne ustanove, a uzorci su uzeti s različitih mjesta kako bi se potvrdila izvedivost pristupa i pomoglo pokriti spektar i varijacije ulaznih parametara modela za predviđanje. Pristup se sastoji od nekoliko koraka [42]:

- 1.) razložiti obrazovni objekt na višestruke hijerarhije, poput katova, sustava, zona ili prostora;
- 2.) stvoriti kodni sustav i razviti bazu podataka odabranog elementa u MSExcel-u;
- 3.) odrediti komponente odabranog elementa i moguće nedostatke u svakoj komponenti;
- 4.) izraditi matricu nedostataka/utjecaja komponenata kako bi se dobilo proporcionalnu težinu svake komponente u elementu;
- 5.) provesti vizualni pregled elemenata promatranog objekta;†
- 6.) identificirati ulazne i izlazne parametre za razvoj modela ANN i OLS, trenirati i testirati ANN model radi potvrde ispravnosti rada i usporediti rezultate s OLS modelom koristeći statističke pokazatelje.

Tijanić Štrok i sur. razvili su 2023. godine model za procjenu stanja školskih zgrada. Model uključuje građevinske komponente i sustav vizualnog ocjenjivanja stanja. Otkriveno je da su mehanički sustavi škola u najlošijem stanju, pri čemu je sustav za hlađenje prostora dobio najnižu ocjenu, dok su grede dobile najvišu ocjenu među konstrukcijskim elementima zgrade. Rezultati su ukazali na to da su škole koje su bile predmet istraživanja općenito u dobrom stanju. Nadalje, rezultati pokazuju da financijska ograničenja i propadanje imaju najveći utjecaj na stanje školskih zgrada. Prema autorima, glavni nedostatak istraživanja je to što njihov sustav BCA ne pruža informacije o specifičnom tipu, lokaciji, izvoru i učinku oštećenja [95].

U tablici 4 nalazi se sažeti prikaz prethodnih istraživanja o procjeni stanja obrazovnih zgrada.

Tablica 4 Sažeti prikaz prethodnih istraživanja o procjeni stanja obrazovnih zgrada

Izvor	Godina	Kriteriji procjene	Svrha ocjene	Metoda prikupljanja podataka	Metoda obrade podataka i korišteni alati
-------	--------	--------------------	--------------	------------------------------	--

Begić Juričić, Hana, 2025, *Razvoj sustava procjene stanja školskih zgrada i modela procjene potrošnje energije, energenata i vode*. Doktorska disertacija. Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek.

Ahluwalia [46]	2008	Na temelju nedostataka zgrade	Poboljšanje procesa održavanja	Vizualni pregled i anketni upitnici	Obrazac i statistička analiza
Che-Ani [85]	2010	Na temelju starosti škole i njezinih nedostataka	Povećanje učinkovitosti inspekcije	Vizualni pregled	Obrazac i matrica
Eweda [70]	2012	Na temelju prostora i nedostataka zgrade	Upravljanje imovinom	Vizualni pregled	BIM i statistička analiza
ElSamadony i sur. [90]	2013	Podaci o održavanju, vrsta škole, geografski podaci i starost	Za planiranje inspekcija	Baza podataka	ANN
Marzouk i Awad [91]	2016	Prioriteti održivosti	Poboljšanje procesa održavanja	Baza podataka prošlih inspekcija	Obrazac, AHP i „fuzzy“ logika
Sadick i Issa [92]	2018	Karakteristike zgrade i prilagodbe korisnika	Utvrđivanje fizičkog stanja elemenata i zdravlja	Baza podataka	Obrazac i statistička analiza
Linggar, Aminullah i Triwyiono [93]	2019	Na temelju nedostataka zgrade	Bolje planiranje i provođenje strategije obnove i održavanja	Anketni upitnici	Obrazac, analiza potvrdnih faktora, tehnike strukturalnog modeliranja jednadžbi i teorija višekriterijske korisnosti
Mohamed i Marzouk [41]	2021	Na temelju nedostataka zgrade	Donošenje odluka u s vezi održavanjem	Anketni upitnici	ANN i računalni softver
Kejeh, Nwaogazie i Samuel [94]	2022	Izgled zgrade, funkcionalnost vodoopskrbnog sustava i sustava odvodnje	Predviđanje stanja održavanja	Vizualni pregled i anketni upitnici	Obrazac i matrica
Hassan i sur. [42]	2022	Na temelju nedostataka zgrade	Donošenje odluka za plan	Vizualni pregled	Kontrolna lista, ANN i OLS

Begić Juričić, Hana, 2025, *Razvoj sustava procjene stanja školskih zgrada i modela procjene potrošnje energije, energenata i vode*. Doktorska disertacija. Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek.

			preventivnog održavanja		
Tijanić Štrok i sur.	2023	Na temelju nedostataka zgrade	Ocjena stanja zgrada	Vizualni pregled i anketni upitnici	Sustavna vizualna ljestvica ocjenjivanja stanja

Velik broj istraživanja proveden je s ciljem pronalaženja odgovarajućih standarda za ocjenjivanje. Ispravnost subjektivnog postupka pregleda na terenu, međutim, ima značajan utjecaj na rezultate procesa ocjenjivanja, neovisno o korištenim kriterijima i njihovoj razini detaljnosti. Trenutne metode često zahtijevaju stručnjaka da procijeni stanje na temelju različitih kriterija dok se pregled provodi. Kao rezultat toga, takvi pregledi su često skupi i oduzimaju puno vremena [96]. Primarni problem koji se spominje u literaturi je subjektivnost stručnjaka prilikom ocjenjivanja stanja sustava ili komponenti zgrade [97].

Činjenica da je malo zemalja učinilo sustav procjene stanja zakonski obveznim također ne motivira vlasnike i upravitelje zgrada da ga koriste [98]. Kako bi se postiglo održivo upravljanje, nužno je stvaranje jeftinog i pouzdanog sustava za ocjenjivanje koji koristi standardizirane postupke i mjerenja, smanjuje troškove pregleda i zahtijeva razumnu količinu vremena.

3. PREGLED PRETHODNIH ISTRAŽIVANJA O ANALIZI I

PROCJENI POTROŠNJE ENERGIJE, ENERGENATA I VODE U OBRAZOVNIM ZGRADAMA

3.1. Potrošnja energije, energenata i vode u obrazovnim zgradama

Utvrđeno je da potrošnja energije zgrada u mnogim zemljama čini više od 40 % ukupne potrošnje energije [99-101]. U ukupnoj potrošnji energije u zgradama, potrošnja energije u obrazovnim zgradama ima značajan udio [102]. Osim toga, potrošnja energije u školi važan je faktor koji pridonosi ukupnim uporabnim troškovima ustanove. Nakon plaća nastavnika i ostalog osoblja, izdaci za energiju predstavljaju drugi najveći izdatak [103]. Također, predviđanje potrošnje energije u zgradi primarni je cilj upravljanja energijom u zgradi i upravitelja objekata [104].

Potrošači energije u školama pokazuju drugačija obilježja u odnosu na korisnike javnih i stambenih zgrada, posebice u pogledu aktivnosti i trajanja boravka unutar same zgrade. Također, zaposlenicima i učenicima nedostaje motivacije za štednju energije u školi kao što ju imaju u vlastitim domovima jer posjeduju ograničeno znanje o količini i cijeni energije koja se koristi, a prostorije i uređaje uglavnom koristi više osoba [105]. S obzirom na znatnu i fluktuirajuću potrošnju vode i energije u školama, postaje sve važnije primijeniti tehnike usmjerene na minimiziranje potrošnje tih resursa [106].

Nekoliko zemalja istaknulo je problem značajne potrošnje energije u nestambenim zgradama. Na primjer, u Ujedinjenom Kraljevstvu postoji 2 milijuna nestambenih zgrada, koje proizvode 19 % ukupnih emisija CO₂ u zemlji i koje predstavljaju značajan potencijal za smanjenje štetnih emisija [107]. U Kanadi, školske zgrade troše 30 % energije koju troši cijeli javni sektor [108]. Nadalje, školske zgrade čine oko 13 % ukupne potrošnje energije u SAD-u, 4 % u Španjolskoj i 10 % u Velikoj Britaniji [6, 109].

Mnogi različiti elementi utječu na potrošnju energije školske zgrade [6, 103, 110]. Stoga je ključno identificirati te elemente tijekom izrade modela predviđanja potrošnje energije. Predviđanje potrošnje energije ključno je kako bi se očuvala energija, osigurala optimalna uporaba i spriječilo nepotrebno rasipanje energije [111, 112]. Prepreka tome je da je izrada preciznih predviđanja često izazovna zbog nepredvidivih okolnosti i nesređenosti podataka, a korištene tehnike često proizvode netočne prognoze [113]. Procjena potrošnje energije u školama ključna je za učinkovito upravljanje resursima, uštede troškova i održivost [114]. Točne procjene omogućuju školama optimizaciju potrošnje energije, smanjenje emisije ugljikovog dioksida te učinkovitu alokaciju resursa, potičući kulturu održivosti i odgovornog upravljanja energijom unutar obrazovne zajednice [115].

Tijekom posljednjih nekoliko desetljeća predložene su brojne metode za procjenu potrošnje energije u zgradama. Većina istraživanja koristi povijesne podatke o potrošnji energije za izradu modela procjene. Metodologije razvijene za procjenu potrošnje energije u zgradama mogu se klasificirati u dvije kategorije: statističke metode i umjetna inteligencija [116]. Opsežan pregled alata temeljenih na povijesnim podacima za procjenu potrošnje energije u zgradama od strane Olu-Ajayi i sur. ističe da su ANN postigle bolje rezultate u više istraživanja od statističkih alata kao što je višestruka linearna regresija (engl. *Multiple Linear Regression* (MLR)). Ipak, MLR je pokazala optimalne rezultate u određenim scenarijima, kao što je procjena godišnje potrošnje energije [117].

3.2. Prethodna istraživanja o analizi potrošnje energije, energenata i vode u obrazovnim zgradama

3.2.1. Prethodna istraživanja o analizi potrošnje električne i toplinske energije u obrazovnim zgradama

Butala i Novak izvršili su temeljite energetske preglede 24 školske zgrade u Sloveniji 1999. godine. Pregledi su otkrili povećanu potrošnju energije i nedovoljnu kvalitetu unutarnjeg zraka, što je prijavilo 60 % učenika. Prosječna godišnja potrošnja energije za grijanje, potrošnu toplu vodu i rasvjetu utvrđena je u iznosu od 192 kWh/m²/god [118].

Kim i sur. proveli su istraživanje kako bi utvrdili optimalnu razinu kvantitativne potrošnje energije školskih zgrada za održavanje ugodnog školskog okruženja i postizanje dobrih performansi uz osiguranje učinkovite upotrebe energije i kontrole. Provedena je analiza potrošnje energije 10 osnovnih škola u Daegu, gradu u južnoj regiji Južne Koreje. U analizi su uzeti u obzir podaci od siječnja 2006. do prosinca 2010. godine i ispitana je potrošnja energije po godini, jedinici površine i po korisniku. Utvrđeno je da je potrošnja energije po jedinici površine bila 289 kWh/m²/god za električnu energiju, 26 kWh/m²/god za naftu i 90 kWh/m²/god za plin [119].

Wang je proveo istraživanje o potrošnji energije u 67 viših srednjih škola, 62 niže srednje škole i 102 osnovne škole u Tajvanu. Njihove vrijednosti korištenja energije (kWh/m²/god) bile su 55,8, 22,5 i 20,1 dok je njihova potrošnja energije po osobi (kWh/osoba/god) bila 1163, 469, odnosno 465. Utvrđeno je da viši razredi srednjih škola koriste značajno veću količinu energije u usporedbi s osnovnim i nižim razredima zbog većih i klimatiziranih učionica te dodatnih sadržaja. Također, privatne škole pokazale su mnogo veću potrošnju energije, potencijalno zbog svojih kvalitetnijih uvjeta učenja, opreme za podučavanje i većeg prosječnog broja učenika u razredu. Autori naglašavaju da bi se rezultati ovog

istraživanja mogli koristiti kao vodič vladinim tijelima u razvoju politika očuvanja energije za školske zgrade [120].

Antunes i Ghisi proveli su analizu potrošnje energije u javnim školama u južnoj regiji Brazila. Podaci o korištenju vode prikupljeni su iz 62 škole, dok su podaci o potrošnji energije prikupljeni iz 100 škola. Podaci o potrošnji energije dobiveni su od siječnja 2016. do svibnja 2017. godine, a prosjek je iznosio 7,15 kWh/učenik/mj u srednjim školama, dok je za niže škole dobiven prosjek od 5,30 kWh/učenik/mj. Utvrđeno je da postoji velika varijacija u potrošnji vode (0,81–35,43 l/učenik/dan), kao i velika varijacija u potrošnji energije (0,31–66,47 kWh/učenik/mj) [106].

Chung i Yeung proveli su istraživanje o potrošnji energije u 121 srednjoj školi, što je činilo 25,6 % ukupnog broja srednjih škola u Hong Kongu. Utvrđeno je da je prosječna potrošnja energije po školi 529,925 kWh i 105,61 kWh/m²/god [121].

Katafygiotou i Serghides proveli su istraživanje o prosječnoj potrošnji energije u školama na Cipru korištenjem upitnika, terenskih inspekcija i intervjua s upraviteljima škola i tehničkim osobljem. Stvarna potrošnja energije školskih zgrada procijenjena je na temelju mjesečnih računa, a istraživanjem je utvrđeno da škole imaju prosječnu godišnju potrošnju od 62,75 kWh/m² [6].

Autori Daly i sur. analizirali su podatke o korištenju energije za 3701 javnu osnovnu školu i utvrđeno je da je prosječna potrošnja energije iznosila 38,0 kWh/m²/god i 542 kWh/učenik/god [122].

Beusker i sur. proveli su istraživanje koje je analiziralo elemente koji utječu na potrošnju energije za grijanje u općinskim školama i sportskim objektima. Istraživanje je bilo temeljeno na nasumičnom uzorku od 105 objekata u Stuttgartu. Utvrđeno je da konačna potrošnja energije u analiziranim školama varira od 31 do 205 kWh/m²/god, a prosječna potrošnja iznosi 93 kWh/m²/god [123].

Kim i sur. proveli su istraživanje o potrošnji energije u devet škola u Koreji. Utvrđeno je da se potrošnja svake škole procjenjuje na 400-1750 MWh/god. Potrošnja električne energije iznosila je cca. 82 % ukupne potrošnje energije ispitanih škola, a ukupljenog prirodnog plina 14 % i kerozina 4 %. Škole koje koriste ventilatore za hlađenje imale su značajno manju potrošnju energije od škola s električnom dizalicom topline. Utvrđeno je da godišnja potrošnja energije po jedinici površine po školama iznosi približno 67-240 kWh/m²/god, što značajno varira između škola, dok je prosječna godišnja potrošnja energije anketiranih škola 133 kWh/m²/god [119].

Begić Juričić, Hana, 2025, *Razvoj sustava procjene stanja školskih zgrada i modela procjene potrošnje energije, energenata i vode*. Doktorska disertacija. Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek.

Hernandez i sur. analizirali su uzorak irskih osnovnih škola koristeći upitnike kako bi dobili informacije o potrošnji energije u školama te su primili 88 odgovora koji su korišteni za detaljnu analizu. Utvrđeno je da prosječna godišnja potrošnja toplinske energije iznosi 96 kWh/m²/god [124].

Santamouris i sur. proveli su detaljno istraživanje o potrošnji energije u 10 škola. Autori su otkrili da je srednja godišnja potrošnja energije za grijanje 57 kWh/m²/god i 20 kWh/m²/god za električnu energiju [125].

Hong i sur. analizirali su potrošnju energije u 7731 osnovnoj i srednjoj školi u Engleskoj gdje su rezultati pokazali da je prosječna potrošnja za osnovne škole iznosila 166 kWh/m²/god, a za srednje škole 172 kWh/m²/god [108, 126].

Attia i sur. razvili skup podataka o energetskej učinkovitosti i dva referentna modela simulacije performansi zgrade za visokoučinkovite škole u Belgiji. Rezultati istraživanja pokazuju da je prosječna potrošnja iznosila 59 kWh/m²/god za osnovne škole i 42 kWh/m²/god za srednje škole [127].

Katić i sur. proveli su istraživanje koristeći se statističkom analizom podataka prikupljenih iz dokumenata detaljnih energetskeh pregleda za 185 školskih objekata u Federaciji Bosne i Hercegovine u odnosu na razdoblja izgradnje. Autori su analizirali vrijeme izgradnje, karakteristike ovojnice zgrade, klimatske uvjete, učinkovitost instaliranog sustava grijanja prostora, broj korisnika i način grijanja. Analizom je utvrđeno da promatrane škole imaju prosječnu potrošnju toplinske energije od 171,90 kWh/m²/god [128]

Jurišević i sur. analizirali su specifičnu potrošnju toplinske energije obrazovnih zgrada u Kragujevcu u Srbiji. Zgrade su razvrstane po obrazovnim razinama i to: zgrade predškolskog odgoja, osnovne i srednje škole te fakulteti (zgrade sveučilišta). Podaci o potrošnji toplinske energije prikupljeni su tijekom nekoliko sezona grijanja kako bi se smanjio utjecaj sezonskih klimatskih varijacija. Ustanovljeno je da su zgrade vrtića i osnovnih škola prioriteta energetske obnove budući da je njihova prosječna specifična potrošnja topline najveća (186 kWh/m²/god, odnosno 176 kWh/m²/god) [129].

U tablici 5 dan je sažeti prikaz prethodnih istraživanja o potrošnji energije u obrazovnim zgradama.

Tablica 5 Sažeti prikaz prethodnih istraživanja o potrošnji energije u obrazovnim zgradama

Izvor	Godina	Država	Vrsta obrazovne zgrade	Mjerna jedinica	Potrošnja	Vrsta energije	Veličina uzorka
-------	--------	--------	------------------------	-----------------	-----------	----------------	-----------------

Begić Juričić, Hana, 2025, *Razvoj sustava procjene stanja školskih zgrada i modela procjene potrošnje energije, energenata i vode*. Doktorska disertacija. Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek.

Butala i Novak [118]	1999	Slovenija	Srednja	kWh/m ² /god	192	Toplinska, potrošna topla voda i rasvjeta	24
Santamouris i sur. [125]	2007	Grčka	Nije definirano	kWh/m ² /god	57	Toplinska	10
					20	Električna	
Hernandez i sur. [124]	2008	Irska	Osnovna	kWh/m ² /god	96	Toplinska	88
Beusker i sur. [123]	2012	Njemačka	Osnovne i srednje sa sportskim terenom	kWh/m ² /god	93	Toplinska	105
Hong i sur. [126]	2013	Engleska	Osnovna	kWh/m ² /god	166	Toplinska	7731
			Srednja		172		
Kim i sur. [119]	2012	Južna Koreja	Osnovna	kWh/m ² /god	289	Električna	10
					26	Ulje	
					90	Nafta	
Katafygiotou i Serghides [6]	2014	Cipar	Srednja	kWh/m ² /god	62,75	Toplinska i električna	156
Jurišević i sur. [129]	2018	Srbija	Vrtić	kWh/m ² /god	186	Toplinska	15
			Osnovna		176		14
			Srednja		136,37		8
			Fakultet		117,1		5
Antunes i Ghisi [106]	2019	Brazil	Viša srednja	kWh/učenik/mj	7,15	Električna	100
			Niža srednja		5,30		
Kim i sur. [130]	2019	Južna Koreja	Srednja	kWh/m ² /god	133	Toplinska i električna	9
Wang [120]	2019	Tajvan	Viša srednja	kWh/m ² /god	55,8	Plin, nafta i električna	67
			Niža srednja		22,5		62
			Osnovna		20,1		102
Chung i Yeung [121]	2020	Hong kong	Srednja	kWh/m ² /god	105,61	Električna	121
	2020	Belgija	Osnovna	kWh/m ² /god	59	Ukupna	30

Attia i sur. [127]			Srednja		42		
Katić i sur. [128]	2021	Bosna i Hercegovina	Osnovne i srednje	kWh/m ² /god	171,90	Toplinska	185
Daly i sur. [122]	2022	Australija	Osnovna	kWh/m ² /god	38	Plin i električna	3701
				kWh/učenik/god	392		

3.2.2. Prethodna istraživanja o analizi potrošnje vode u obrazovnim zgradama

Budući da obrazovne zgrade čine značajan dio nestambenih zgrada, ključno je usmjeriti inicijative za uštedu vode na te objekte [14-16]. Također, dostupnost i korištenje vode u školama značajno utječu na zdravlje i čistoću okruženja za učenje [131]. Pretjerana potrošnja vode u školi može biti rezultat nepravilnog korištenja ili rasipanja. Ipak, minimalna potrošnja vode nije u skladu s konceptima zdravlja i higijene [132]. Unatoč važnosti, istraživanja o potrošnji vode u školama relativno su rijetka širom svijeta, kako su primijetili Morote i sur. [133].

Cheng i Hong istraživali su potrošnju vode u osnovnim školama kako bi potaknuli štednju vode. Prvo je stvorena baza podataka koja dokumentira potrošnju vode u osnovnim školama. Upitnici su distribuirani pojedinim osnovnim školama putem pošte. Svaki odgovor je pregledan u vezi s geografskom lokacijom škole, brojem učenika i učitelja, omjerom muškaraca i žena te drugim varijablama. Analizirani podaci prikupljeni su iz 112 osnovnih škola u gradu Taipei u Tajvanu. Utvrđeno je da je ukupna prosječna potrošnja vode u analiziranim školama iznosila 15,27 m³/osobi/god [132].

Schultt i sur. analizirali su 26 javnih osnovnih, nižih srednjih i viših srednjih škola u južnom Brazilu kako bi identificirali čimbenike koji utječu na potrošnju vode u školama. Metode prikupljanja podataka uključivale su mjerenja na licu mjesta i upitnike na koje su ravnatelji odgovarali. Autori su utvrdili da je prosječna mjesečna potrošnja vode iznosila 111,45 m³/škola/mj, dok je prosječna potrošnja vode po učeniku bila 8,833 L/učenik/dan [134].

Farina i sur. analizirali su potrošnju vode za 600 zgrada u Bologni u Italiji koje su praćene više od pet godina. Istraživanje je ispitivalo dnevnu potrošnju triju odgojno-obrazovnih ustanova: jaslica, vrtića i osnovnih škola, te istraživala odnos između potrošnje i broja korisnika zgrade. Autori su zaključili da je razlika u vrstama škola izravno povezana s različitim namjenama i dobi učenika. Otkrili su da učenici osnovnih škola nalikuju korisnicima uredskih zgrada u smislu prisutnosti tijekom radnog vremena i primarne upotrebe vode u toaletima i za opće svrhe. Na kraju, utvrđeno je da se racionalna osnovna

potreba za vodom procjenjuje na 48 litara po djetetu u vrtiću dnevno i 18 litara po učeniku osnovne škole dnevno [135].

Almeida i sur. proveli su istraživanje koje je analiziralo 23 školske zgrade na sjevernoj obali Portugala. Sve zgrade u uzorku bile su u izvornom stanju i većinom novoizgrađene; preko 40 % uzorka bilo staro manje od 20 godina [136]. Troškovi energije i vode svake zgrade prikupljeni su iz odgovarajućih mjesečnih računa koje je školski odbor dostavio tijekom jedne godine. Otkrili su da je električna energija glavni uporabni trošak, dok je voda drugi najznačajniji. Također, primijećeno je da električna potrošnja pokazuje uočljive sezonske fluktuacije, s povećanom potražnjom tijekom zimskih mjeseci. Međutim, nije uočen opaženi trend u potrošnji vode [137].

Morote i sur. proučavali su potrošnju vode u osnovnim i srednjim školama u Alicanteu u Španjolskoj od 2000. do 2017. godine. Rezultate su dobili putem anketa koje su distribuirali ravnateljima škola. Od 88 zahtjeva, samo je 14 ravnatelja pristalo sudjelovati u istraživanju. Autori istraživanja istaknuli su da je najveće ograničenje bio nizak postotak odgovora, unatoč tome što su kontaktirali ravnatelje tri puta. Utvrđeno je da potrošnja vode u školama ovisi o nekoliko čimbenika, uključujući broj učenika i zaposlenika, zalijevanje vanjskih prostora, vrste vrtova, učinkovitost sustava za zalijevanje, upotrebu opreme za uštedu vode te aktivnosti čišćenja [133].

Nunes i sur. nastojali su identificirati kriterije za racionalnu upotrebu vode u javnim školama u Brazilu. Tehnika je obuhvaćala sljedeće komponente: odabir škole, identifikaciju svih područja gdje se voda koristi u školi, otkrivanje slučajeva curenja vode ili kvarova, provođenje anketa za evaluaciju percepcije potrošača, izračun pokazatelja potrošnje, indeksa curenja i indeksa percepcije korisnika radi promicanja učinkovite upotrebe vode. Autori ističu da rezultati pokazuju da, iako upotreba vode možda nije tako značajna kao što je ranije prikazano u literaturi, škole ipak imaju značajne fizičke gubitke vode i imaju ograničeno razumijevanje učinkovitosti upravljanja vodom [138]. U tablici 6 dan je sažeti prikaz prethodnih istraživanja o potrošnji vode u obrazovnim zgradama.

Tablica 6 Sažeti prikaz prethodnih istraživanja o analizi potrošnji vode u obrazovnim zgradama

Izvor	Godina	Država	Vrsta obrazovne zgrade	Mjerna jedinica	Potrošnja	Veličina uzorka
Cheng i Hong [132]	2004	Tajvan	Osnovna	m ³ /osoba/god	15,27	112
				L/učenik/dan	30	
Farina i sur. [135]	2011	Italija	Vrtić	L/učenik/dan	48	600
			Osnovna		18	

Nunes I sur. [138]	2018	Brazil	Nije definirano	L/učenik/dan	8,58	6
Schultt i sur. [134]	2019	Brazil	Osnovna, niža srednja i visa srednja	m ³ /škola/mj	111,5	26
				L/učenik/dan	8,8	26
Morote i sur. [133]	2020	Španjolska	Osnovna i srednja	L/učenik/dan	7,34	14

3.3. Prethodna istraživanja o procjeni potrošnje energije, energenata i vode u obrazovnim zgradama

3.3.1. Prethodna istraživanja o procjeni potrošnje električne i toplinske energije u obrazovnim zgradama

Capozzoli i sur. analizirali su potrošnju energije za grijanje u 80 školskih zgrada na sjeveru Italije. Razvili su i evaluirali dva modela, jedan koristeći MLR i model klasifikacije i regresijskog stabla (engl. *Classification and Regression Tree* (CART)), kako bi procijenili potrošnju energije. Oba modela evaluirana su na temelju statističkih koeficijenata. Analiza je zaključila da bruto grijani volumen, površine prijenosa topline, veličina kotla i toplinska provodljivost prozora primarno utječu na potrošnju energije za grijanje školskih zgrada koje su bile predmet istraživanja [139].

Beusker i sur. proveli su empirijsko istraživanje koje je analiziralo elemente koji utječu na potrošnju energije za grijanje u gradskim školama i sportskim objektima. Istraživanje je temeljeno na slučajnom uzorku od 105 objekata u Stuttgartu u Njemačkoj. Različiti linearni i nelinearni regresijski modeli sustavno su razvijeni i evaluirani kako bi se prognozirala potrošnja energije za grijanje. Autori su istaknuli da predloženi model pokazuje visoku točnost i zadovoljava sve potrebne karakteristike za učinkovitu procjenu [123].

Mohammed i sur. predložili su model temeljen na višestrukoj regresiji za procjenu potrošnje energije školskih objekata u Saudijskoj Arabiji. Autori naglašavaju da model pruža praktičan i ekonomičan pristup koji vladine institucije mogu koristiti u procjeni potrošnje energije [113].

Alshibani je proveo istraživanje u Istočnoj provinciji Saudijske Arabije kako bi utvrdio čimbenike koji utječu na potrošnju energije u školskim objektima. Korištena su 352 stvarna skupa podataka o potrošnji energije iz škola. Razvijeni model procjene potrošnje energije uključuje jedanaest parametara koji utječu na potrošnju energije izgrađenih škola, a ti su parametri korišteni kao ulazne varijable za izradu modela. Kreirani model validiran je na osam stvarnih primjera, pri čemu je pokazao točnost od 87,5 %.

Istraživanje je identificiralo "kapacitet klima uređaja" kao najutjecajniji faktor, nakon čega slijedi "ukupna površina krova škole" [140].

Ding i sur. predstavili su metodologiju koja omogućuje prognoziranje godišnjih uzoraka potrošnje energije na satnoj osnovi. Autori ističu da specifični profili opterećenja mogu točno prikazivati suvremene energetske zahtjeve nordijskih škola, a tehnike koje su korištene mogu se proširiti na druge vrste zgrada [115].

Faiq i sur. predložili su uporabu neuronske mreže s dugom kratkoročnom memorijom (engl. *Long Short-Term Memory* (LSTM)) za procjenu potrošnje energije sveučilišne zgrade. Model za procjenu razvijen je analizom veza između potrošnje energije i meteoroloških podataka. Također, LSTM zahtijeva uključivanje vanjskih varijabli, poput okolišnih faktora (npr. temperatura i brzina vjetra), kako bi se poboljšala preciznost prediktivnog modela. Autori predlažu da buduća istraživanja mogu unaprijediti model uključivanjem dodatnih karakteristika kao što je broj korisnika zgrade [141].

Cao i sur. predložili su model za procjenu potrošnje energije u obrazovnim ustanovama kombinirajući geografske varijable i vremenske nizove podataka. Valjanost predloženog modela potvrđena je primjenom na obrazovnu ustanovu smještenu u Xi'anu u provinciji Shaanxi. Rezultati pokazuju da integrirani model procjene potrošnje energije pokazuje smanjenje srednje kvadratne pogreške (engl. *Root Mean Square Error* (RMSE)) vrijednosti u rasponu od 13,64 % do 34,55 % u usporedbi s prethodnim prediktivnim modelima. Također, srednja apsolutna pogreška (engl. *Mean Absolute Error* (MAE)) je smanjena u rasponu od 10,25 % do 30,54 %, što ukazuje na poboljšanu točnost prognoze [142].

Shahid i sur. razvili su prediktivni model za procjenu potrošnje električne energije i toplinske energije. Koristili su napredne tehnike strojnog učenja poput rekurentne neuronske mreže (engl. *Recurrent Neural Network* (RNN)), LSTM-a, konvolucijskih neuronskih mreža (engl. *Convolutional Neural Network* (CNN)) i autoenkodera (engl. *Autoencoders* (AE)). Model je treniran koristeći stvarne podatke o potrošnji iz šest javnih škola u jednoj švedskoj općini. Eksperimentalni rezultati pokazuju da je model postigao visoku razinu točnosti, s vrijednostima RMSE i nRMSE koje variraju od 18 % do 25 % za električnu energiju, te od 20 % do 30 % RMSE i 5 % nRMSE za toplinsku energiju [143].

Elhabyb i sur. razvili su prediktivni model za potrošnju električne energije u tri sveučilišne zgrade na temelju skupa podataka prikupljenih od siječnja 2020. do siječnja 2023. Razvoj prediktivnog modela obuhvatio je pripremu podataka, kao što je popunjavanje nedostajućih podataka i određivanje značajnosti ulaznih varijabli. Koristili su tri tehnike strojnog učenja, gradijentnog pojačavanja (engl. *Gradient Boosting Regressor* (GBR)), LSTM i algoritma nasumične šume (engl. *Random Forest* (RF)), kao

algoritme za prediktivni model. Kao smjernice za daljnja istraživanja, autori predlažu korištenje naprednijih računalnih sustava ili platformi za izvođenje LSTM algoritma, što može poboljšati ukupnu izvedbu [144].

Doiphode i Najafi predložili su korištenje višeslojne perceptronske neuronske mreže (engl. *Multi-Layer Perceptron* (MLP)) za procjenu mjesečne potrošnje energije u školama K-12 u okrugu Brevard na Floridi u Sjedinjenim Američkim Državama. Ulazne varijable uključuju broj stanovnika, broj radnih dana mjesečno, površinu zgrade, prosječnu mjesečnu vanjsku temperaturu i relativnu vlažnost, dok je izlazna varijabla mjesečna potrošnja energije. Odabrana mreža je učinkovito trenirana koristeći trogodišnje podatke o potrošnji energije iz 25 srednjih i osnovnih škola [145].

Soares Geraldi i sur. predstavili su prediktivni model razvijen koristeći Bayesove mreže za procjenu potrošnje energije. Autori su prikupili mjesečne račune tijekom razdoblja od tri godine iz 90 javnih škola smještenih na jugu Brazila. Također su prikupili informacije o površini svake škole, broju učenika, razini obrazovanja, broju katova i učestalosti događaja u zgradi. Kao moguće smjerove za buduća istraživanja, autori predlažu poboljšanje baze podataka uključivanjem više karakteristika [146].

Run i sur. su primijenili model višestruke linearne regresije kako bi predvidjeli satnu potrošnju električne energije u školskim zgradama na jugu Francuske tijekom zimske sezone. Analiza je pokazala da je koeficijent determinacije (engl. *Coefficient of determination* (R^2)) za skup podataka za trening 74 %, dok je za skup podataka za validaciju 77 % [147].

Li i sur. predložili su metodu za kratkoročnu prognozu potrošnje električne energije za hlađenje, fokusirajući se na nesigurne obrasce korištenja koji su pod utjecajem ponašanja korisnika. Primijenjena na obrazovnu zgradu, metoda koristi analizu klastera za prepoznavanje tipičnih obrazaca i tehniku ponderiranih k-najbližih susjeda za predviđanje. Zatim se razvija RF model koji procjenjuje značaj svake varijable. Kako bi se poboljšala točnost u nepredvidivim uvjetima, koristi se stroj s potpornim vektorom (engl. *Support Vector Machine* (SVM)). Rezultati pokazuju da oba modela učinkovito predviđaju potrošnju energije za hlađenje, ali poboljšani model nudi znatno veću točnost u nesigurnim uvjetima [148].

Tariq i sur. proveli su istraživanje koje istražuje različite modele umjetne inteligencije, poput stabala odluka, k-najbližih susjeda, GBR-a i LSTM-a, za predviđanje potrošnje električne energije u školama, naglašavajući utjecaj čimbenika poput veličine škole i kapaciteta klimatizacije na godišnju potrošnju. Rezultati pokazuju da dok stabla odluka dobro funkcioniraju u fazi treniranja s niskim pogreškama

predviđanja, k-najbliži susjedi imaju problema s preprilagođavanjem (engl. *overfitting*). GBR i LSTM modeli se izvrsno nose s raznolikim rasponima podataka [149].

U tablici 7 dan je sažeti prikaz prethodnih istraživanja o procjeni potrošnje električne i toplinske energije u obrazovnim zgradama.

Tablica 7 Sažeti prikaz prethodnih istraživanja o procjeni potrošnje električne i toplinske energije u obrazovnim zgradama

Izvor	Godina	Država	Vrsta obrazovne zgrade	Korištena metoda za razvoj modela	Vrsta energije	Veličina uzorka
Beusker i sur. [123]	2012	Njemačka	Osnovne i srednje sa sportskim terenom	Linearna i nelinearna regresija	Toplinska	105
Capozzoli i sur. [139]	2015	Italija	Nije definirano	MLR i CART	Toplinska	80- razvoj
						5- validacija
Soares Geraldi i sur. [146]	2019	Brazil	Osnovne i srednje	Bayesova mreža	Električna	90
Alshibani [58]	2020	Saudijska Arabija	Osnovne, srednje i više	ANN	Električna	352
Doiphode i Najafi [63]	2020	Florida, SAD	Osnovne i srednje	MLP	Toplinska i električna	25
Mohammed i sur. [21]	2021	Saudijska Arabija	Nije definirano	Regresija	Toplinska i električna	350- razvoj
						35- validacija
Ding i sur. [54]	2021	Norveška	Nije definirano	MLR	Električna	40
Cao i sur. [60]	2023	Kina	Kompleks osnovne i srednje	SHAP metoda	Električna	1
Faiq i sur. [59]	2023	Malezija	Sveučilišna zgrada	LSTM	Električna	1
Run i sur. [65]	2023	Francuska	Osnovne i srednje	MLR	Električna	9
Shahid i sur. [61]	2023	Švedska	Osnovne i srednje	RNN, LSTM, CNN i AE	Toplinska i električna	6
Elhabyb i sur. [62]	2024	Indija	Sveučilišne zgrade	GBR, LSTM i RF	Električna	3

Li i sur. [148]	2023	Kina	Sveučilišne zgrade	Klaster analiza, k-najbliži susjedi, RF i SVM	Električna	1
Tariq i sur. [149]	2024	Saudijska Arabija	Osnovne i srednje škole	Drvo odluke, k-najbliži susjedi, GBR i LSTM	Električna	352

3.3.2. Prethodna istraživanja o procjeni potrošnje vode u obrazovnim zgradama

Almeida i sur. proveli su istraživanje na temu procjene potrošnje energije i vode na Paricarana kampusu sveučilišta Roraima u Brazilu. Metodologija istraživanja uključivala je mjerenje vremena za punjenje jedne litre vode kao metodu za određivanje protoka vode iz različitih instalacija. Također su provedeni intervjui s administratorima zgrada kako bi se identificirale aktivnosti u prostorijama i zgradama, što je omogućilo procjenu vremena rada opreme za osvjetljenje i hlađenje. Za procjenu navika potrošnje akademske populacije korišteni su i neizravni upitnici poslani putem e-maila tijekom lipnja 2017. Istraživanje je također uključilo izravne ankete za procjenu potrošnje vode u čišćenju prostorija [150]. Jurišević i sur. analizirali su potrošnju vode u 13 predškolskih zgrada u gradu Kragujevcu u Srbiji u trogodišnjem razdoblju. Autori su utvrdili 21 parametar koji je utjecao na potrošnju vode i razvili šest prediktivnih modela za procjenu potrošnje vode. Ustanovljeno je da je RF algoritam postigao najbolje ukupne performanse, dok je MLR pokazala istu preciznost kao i RF kada se radilo o zgradama koje troše više od 200 m³/mjesечно. Utvrđeno je da obje metode daju zadovoljavajuće procjene, ostavljajući korisnicima izbor između boljih performansi (RF) ili jednostavnosti korištenja (MLR) [151]. U tablici 8 dan je sažeti prikaz prethodnih istraživanja o procjeni potrošnje vode u obrazovnim zgradama.

Tablica 8 Sažeti prikaz prethodnih istraživanja o procjeni potrošnje vode u obrazovnim zgradama

Izvor	Godina	Država	Vrsta obrazovne zgrade	Korištena metoda za razvoj modela	Veličina uzorka
Almeida i sur. [150]	2021	Brazil	Kampus	Pristup mjerenja volumena i vremena	1
Jurišević i sur. [123]	2021	Srbija	Vrtići	MLR i RF	13

3.4. Razlika između stvarne i proračunske potrošnje energije u zgradama

3.4.1. Definicija energetske jaz

Energetski certifikat vrijedi deset godina od datuma izdavanja i sadrži opće informacije o zgradi, energetski razred zgrade, razdoblje valjanosti certifikata, informacije o osobi koja je izdala i izradila energetski certifikat, informacije o osobama koje su sudjelovale u izradi energetskog certifikata, oznaku energetskog certifikata, informacije o termotehničkim sustavima, energetske potrebe zgrade, podatke o korištenju obnovljivih izvora energije, predložene mjere, detaljnije informacije i objašnjenje sadržaja energetskog certifikata [152-154]. Međutim, važno je istaknuti da se pouzdanost energetskih certifikata može dovesti u pitanje, budući da standardni profili korištenja zgrade, period grijanja zgrade prema klimatskoj zoni, uključivanje centralnog grijanja, radni uvjeti, prosječni klimatski uvjeti i ograničene energetske usluge mogu dovesti do značajnih razlika u odnosu na stvarnu potrošnju energije [155, 156].

Jaz između izračunate i stvarne potrošnje energije široko je priznat kao glavni problem u točnoj procjeni izvedbe zgrada i očekivanih prednosti mjera za uštedu energije, osobito u kontekstu dubinske procjene energetske učinkovitosti zgrada u nekoj državi [155]. U literaturi će se češće pronaći na engleskom jeziku kao *Energy Performance Gap*, a na hrvatskom jeziku kao energetska jaz. Također, primijećeno je da se ovaj problem javlja ne samo u postojećim zgradama, već i u novima [157]. Unatoč svrsi energetskih certifikata da pruže informacije o energetske učinkovitosti zgrade, često može doći do razlike između očekivane energetske izvedbe i stvarnih rezultata [158].

U literaturi su prepoznata dva glavna faktora koji doprinose pojavi energetske jaz: nepreciznost u fizičkom prikazu zgrada pri izradi energetskog certifikata i neuzimanje obrazaca ponašanja korisnika u obzir [159, 160]. Dodatni faktori koji doprinose energetske jazu uključuju operativne probleme ili otkazivanja termotehničkog sustava zgrade i pogreške nastale tijekom izgradnje [161]. Što se tiče kvantifikacije energetske jaz, postoji dosljednost među rezultatima nekoliko istraživanja, pri čemu je stvarna potrošnja dosljedno između dva i pet puta veća od izračunate potrošnje [162-165].

Mnoga istraživanja bavila su se energetske jazom diljem svijeta [15, 159, 162, 163, 166-171]. Međutim, takva istraživanja rijetko su se fokusirala na obrazovne zgrade [172-174]. Također, u literaturi je istaknuto da varijacije među zemljama zahtijevaju provođenje istraživanja u vezi s energetske jazom za svaku pojedinu zemlju [168, 175, 176]. U Republici Hrvatskoj postoji samo jedno istraživanje na ovu temu [45], a ne bavi se obrazovnim zgradama.

3.4.2. Pregled prethodnih istraživanja o analizi razlike između stvarne i proračunske potrošnje energije u zgradama

Palladino je analizirao stambene zgrade u Italiji kako bi utvrdio energetske jaz [156]. Ova analiza uzela je u obzir čimbenike kao što su klimatska zona, tip zgrade, način uporabe i razinu toplinske izolacije zgrada. Osim toga, autor je ispitao kako ovi čimbenici utječu na energetske jaz i istraživao učinke „prebouda“ i „rebouda“ [156]. „Prebound“ efekt je kada je stvarna potrošnja niža od izračunate potrošnje. Suprotno tome, „reboud“ efekt nastaje kada stvarna potrošnja premašuje izračunatu potrošnju [177, 178]. Istraživanje je pokazalo širok raspon varijabilnosti u učincima „prebouda“ (od 0 % do +80 %) i „rebouda“ (od -30 % do 0 %) na energetske jaz. Istraživanje je mjerilo prosječnu potrošnju energije po danu grijanja na navedenoj lokaciji, koja je varirala od -3 do +16 kWh, ovisno o profilu uporabe [156].

Hernandez-Cruz i sur. proveli su istraživanje koje je analiziralo mjesečnu potrošnju energije 481 stambene jedinice smještene u šest zgrada socijalnog stambenog fonda u španjolskoj regiji Baskiji, tijekom tri godine. Statistička analiza otkrila je značajnu varijaciju u potrošnji među stanovima unutar iste zgrade. Studija je pokazala da ponašanje korisnika značajno utječe na učinkovitost centraliziranih sustava u zgradama, s prosječnom učinkovitošću od 65 %. Potrošnja energije u tim kompleksima socijalnog stanovanja bila je mnogo niža od regionalnih, nacionalnih i europskih prosjeka. Osim toga, vrijednosti energetskog jaza odstupale su od tipičnih vrijednosti navedenih u literaturi. Konkretno, stvarna potrošnja energije ovih zgrada bila je od 0,70 do 2,28 puta veća od izračunate potrošnje [161].

Nekoliko autora također je proučavalo energetske jaz u energetski učinkovitim zgradama. Padey i sur. izvijestili su o energetskom jazu od 20 do 30 % u energetski učinkovitoj zgradi u Švicarskoj [179]. Coyne i Denny proveli su istraživanje o energetskom jazu 9923 kućanstava, analizirajući stvarne podatke o potrošnji energije od 2014. do 2017. godine. Rezultati pokazuju da energetski certifikat ima mali utjecaj na stvarnu potrošnju energije, a istraživanje je uočilo raspon od 457 kWh/godinu među različitim razinama energetskih certifikata u ukupnom uzorku. Istraživači su također otkrili da su energetski najučinkovitiji stanovi imali prosječan višak od 2998 kWh godišnje, što je 39 % više od izračunate vrijednosti. S druge strane, manje energetski učinkovite kuće imale su nižu stvarnu potrošnju energije nego što su to pokazivale predviđene vrijednosti, dok je prosječna razlika varirala od 24 % za kuće s D energetskim razredom do 56 % za kuće s F i G energetskim razredima [168].

Anđelković i sur. proveli su studiju slučaja u Novom Sadu u Srbiji, kako bi procijenili učinke energetskog certifikata na potrošnju energije, razvoj kapaciteta i potencijalne mjere uštede u sektoru zgradarstva i povezanim komunalnim uslugama. Studija slučaja obuhvatila je zgrade povezane s lokalnim sustavom

daljinskog grijanja, kao i one koje su bile povezane samo s gradskom plinskom mrežom. Rezultati su pokazali značajnu razliku između stvarne i izračunate potrošnje energije. Štoviše, autori su primijetili izraženije razlike u zgradama koje koriste plinske sustave grijanja nego u onima povezanim s daljinskim grijanjem [180].

Motuziene i sur. analizirali su energetske jaz za zgrade s visokom energetske učinkovitosti u Litvi. Analiza je pokazala da energetske jaz pokazuje raspon varijacije od -101 % do +77 % za energetske razred A. Nadalje, energetske razredi A+ i A++ imaju ograničeniji raspon, od +18 do 76 % i +23 do 77 %, respektivno. Rezultati autora slagali su se s nekoliko drugih studija, potvrđujući da zgrade s visokom energetske učinkovitosti troše više energije nego što je inicijalno izračunato. Također je naglašeno da Litva ima isti problem unatoč varijacijama u nacionalnim tehnikama certificiranja, te da su potrebna prilagođavanja za sheme energetskih certifikata [181].

Cozza i sur. proveli su analizu energetskog jaza u stambenim zgradama u Švicarskoj koristeći bazu podataka energetskih certifikata. Istraživači su otkrili da je medijanski energetske jaz bio -11 %. Međutim, on je varirao među različitim energetske razredima, od 12,4 % za energetske razred B do -40,4 % za energetske razred G. Utvrđeno je da zgrade s niskim energetske razredima troše znatno manje energije nego što se očekivalo. Suprotno tome, zgrade s visokim energetske razredima obično troše malo više nego što je predviđeno. Analiza zgrada energetskog razreda A pokazala je energetske jaz od -6,2 %, što ukazuje na to da su visoko učinkovite zgrade možda otpornije na učinke energetskog jaza [167].

3.4.3. Pregled prethodnih istraživanja o analizi razlike između stvarne i proračunske potrošnje energije u obrazovnim zgradama

Kim i sur. istaknuli su da stvarna potrošnja energije u školama može biti 60-70 % veća od izračunate, a čak i do 85 % veća za sveučilišta [182]. Osim toga, Van Dronkelaar i sur. izvijestili su o prosječnom energetske jazu od 67 % za škole, a isti prosječni energetske jaz zabilježen je i za zgrade sveučilišta [169].

Herrando i sur. analizirali su energetske certifikate 32 fakultetske zgrade u gradu Zaragoza u Španjolskoj. Otkrili su da je stvarna potrošnja energije tih zgrada oko 30 % veća od one prikazane u energetske certifikatima [183].

Kim i sur. proveli su studiju slučaja na zgradi sveučilišta u Ujedinjenim Arapskim Emiratima. Provedeni su energetske pregledi, evaluacija nakon početka korištenja i dinamička simulacija kako bi se identificirali uzroci koji doprinose dinamičkom energetske jazu i procijenila učinkovitost strategija za minimiziranje


ovog jaza. Osim toga, podaci o energetske pregledu zgrade i pregled nakon početka korištenja korišteni su za provjeru i prilagodbu modela dinamičke simulacije. Rezultati su pokazali da sustavi zgrade nisu radili kako je predviđeno, što je rezultiralo gubitkom više od 25 % energije za hlađenje. To je pripisano neadekvatnom nadzoru mehaničkih sustava od strane uprave zgrade [182].

Iz pregleda literature jasno je da je prethodno istraživanje na obrazovnim zgradama uglavnom bilo usmjereno na sveučilišne zgrade. S druge strane, istraživanja koja se isključivo bave školskim zgradama još nisu provedena. Ovaj jaz naglašava potrebu za ciljanim istraživanjima fokusiranim na školske zgrade kako bi se adresirali specifični problemi i zahtjevi koji se razlikuju od onih koji se odnose na sveučilišne zgrade.

4. PRIKUPLJANJE PODATAKA

4.1. Pregled stanja i zakonodavnog okvira u Republici Hrvatskoj

Prema izvješću *Energija u Hrvatskoj 2022*, što je ujedno i posljednje dostupno izvješće u trenutku pisanja ovog rada, preko 47 % ukupne potrošnje energije u Republici Hrvatskoj odnosi se na potrošnju energije u zgradama što je vidljivo na slici 1 [184].



Slika 1 Udio ukupne potrošnje energije u zgradama u ukupnoj potrošnji finalne energije Republike Hrvatske za 2022. godinu [184]

Prema podacima Europske komisije, većina zgrada u EU, točnije njih 85 %, izgrađena je prije 2000. godine [11]. Nadalje, značajnih 75 % tih zgrada ima neadekvatnu energetska učinkovitost. Poduzimanje mjera za poboljšanje energetske učinkovitosti zgrada ključno je za očuvanje energije i postizanje cilja stvaranja zgrada koje ne proizvode emisije i potpuno su dekarbonizirane do 2050. godine. Do 11. listopada 2025. države članice EU morat će izraditi i javno objaviti sveobuhvatan popis zgrada koje su u vlasništvu ili ih koriste državne institucije, a čija ukupna korisna površina premašuje 250 m². Ovaj popis mora se ažurirati najmanje jednom svake dvije godine [12]. Osim toga, Direktiva o energetska učinkovitosti zgrada (2010/31/EU), izmijenjena Direktivom (2018/844/EU), zahtijeva od zemalja EU da razviju nacionalne dugoročne strategije obnove, koje moraju uključivati politike i mjere usmjerene na sve javne zgrade [12].

Takva strategija razvijena je i u Republici Hrvatskoj pod nazivom *Dugoročna strategija obnove nacionalnog fonda zgrada do 2050. godine* i objavljena je u prosincu 2020. godine. Glavni cilj ove strategije je identificirati djelotvorne mjere za dugoročno poticanje troškovno učinkovite integralne obnove nacionalnog fonda zgrada Republike Hrvatske do 2050. godine [13].

Direktiva o energetske učinkovitosti (2024/1791/EU) usvojena je u listopadu 2023. godine, a zahtijeva od država članica da ju prenesu u svoje zakonodavstvo do sredine 2025. godine. Ova Direktiva zahtijeva da svaka država članica mora osigurati da se najmanje 3 % ukupne površine poda grijanih i/ili hlađenih zgrada u vlasništvu javnih tijela obnovi svake godine u zgrade gotovo nulte energije (*nearly Zero Emission Buildings* – nZEB) ili zgrade s nultim emisijama (*Zero Emission Buildings* – ZEB) [185].

Direktiva o energetske svojstvima zgrada (2024/1275/EU) stavlja naglasak na obnovu i izgradnju novih zgrada s nultim emisijama te općenito dekarbonizaciju do 2050. godine. Osim toga postavlja minimalne standarde energetske svojstava za obnovu nestambenih zgrada s najlošijim energetske svojstvima [186].

Hrvatska je postavila ambiciozan cilj za sektor zgradarstva, usmjeren prema stvaranju energetske učinkovitog i dekarboniziranog fonda zgrada do 2050. godine. Kako bi uključila sve ključne aktere u proces izgradnje i obnove zgrada s ciljem značajnog smanjenja emisija CO₂ za 80 % do kraja 2050. godine, Ministarstvo prostornog uređenja, graditeljstva i državne imovine (MGIPU) pokrenulo je *Povelju o suradnji za dekarbonizaciju zgrada*. Ova povelja usredotočuje se na postizanje nacionalnih i europskih energetske i klimatske ciljeva putem dekarbonizacije postojećih zgrada, njihove obnove te gradnje zgrada gotovo nulte energetske potrošnje. Ističe se važnost daljnjeg smanjenja emisija stakleničkih plinova, veće korištenje obnovljivih izvora energije, povećanje energetske sigurnosti te uvođenje inovativnih i pametnih tehnologija koje će pomoći dekarbonizaciji gospodarstva. Potpisivanje povelje potiče dugoročnu suradnju na izradi strategije za obnovu zgrada i prijelaz na nZEB standarde gradnje [227].

Uz Ministarstvo zaštite okoliša i energetike (MZOE), ključnu ulogu u provedbi nacionalnih energetske i klimatske politika ima i MGIPU. MGIPU je zaduženo za oblikovanje politika i mjera koje omogućuju ostvarenje ciljeva energetske učinkovitosti u zgradama. Ono donosi zakonske propise, strategije i programe kojima se usmjerava dugoročna i sveobuhvatna obnova različitih vrsta zgrada, uključujući obiteljske kuće, višestambene objekte, komercijalne nestambene zgrade te zgrade javnog sektora [187].

Agencija za pravni promet i posredovanje nekretninama (APN) također ima važnu ulogu u području energetske učinkovitosti. Ona je odgovorna za provođenje programa energetske obnove zgrada javnog

sektora prema modelu energetske usluga, kao i za sustavno upravljanje energijom u javnom sektoru.

Sve aktivnosti provodi u skladu s ovlastima definiranim *Zakonom o energetskej učinkovitosti* (NN 127/14, 116/18, 25/20, 32/21, 41/21) [187].

U Republici Hrvatskoj od 2005. do 2013. godine proveden je projekt pod nazivom *Poticanje energetske efikasnosti u Hrvatskoj (EE projekt)* koji je započet u srpnju 2005. godine kao zajednički projekt tadašnjeg Ministarstva gospodarstva, rada i poduzetništva i Programa Ujedinjenih naroda za razvoj uz financijsku podršku Globalnog fonda za okoliš i Fonda za zaštitu okoliša i energetske učinkovitost [188]. U sklopu toga projekta razvile su se tri glavne komponente: projekt *Sustavno gospodarenje energijom u gradovima i županijama*, Program Vlade RH „Dovesti svoju kuću u red“ te nacionalna informativno-edukativna kampanja. Cilj projekta bio je izgraditi kapacitete za provedbu sustavnog te kontinuiranog gospodarenja energijom u svim zgradama javnog sektora u Hrvatskoj kroz razvoj potrebnih ljudskih, organizacijskih i proceduralnih resursa za gospodarenje energijom, njihovo obrazovanje i opremanje potrebnim alatima za sustavan pristup gospodarenju energijom [189].

Prva verzija *Informacijskog sustava gospodarenja energijom* (ISGE) (engl. *Energy Management Information System* (EMIS)) postala je dostupna korisnicima 2008. godine. Nastavak aktivnosti nacionalnih komponenti projekta preuzele su nacionalne institucije – APN i Fond za zaštitu okoliša i energetske učinkovitost (FZOEU). Nakon toga, 2014. godine donesen je *Zakon o energetskej učinkovitosti 2014.* – koji je implementacija *Direktive o energetskej učinkovitosti* te *Direktive o energetskej učinkovitosti*. Njime je postalo obvezno praćenje potrošnje energije i vode za sve zgrade u vlasništvu ili korištenju javnog sektora (sve središnje i lokalne vlasti) te se u tu svrhu koristi ISGE. Osim toga postalo je obvezno imenovati osobu i tim za energetske učinkovitost na institucionalnoj razini te slanje podataka o energiji i potrošnje vode u zgradama javnog sektora u ISGE sustav od strane dobavljača energije i vode [190]. ISGE predstavlja glavni alat za kontinuirano prikupljanje podataka, praćenje i analizu potrošnje energije i vode u zgradama. Svi podaci o potrošnji energije i vode prikupljeni su u jednu centraliziranu bazu podataka što omogućuje jednostavnu analizu i interpretaciju potrošnje energije i vode s jednog centraliziranog mjesta.


U kontekstu energetske učinkovitosti zgrada važno je spomenuti i energetske certifikate, koje je od 1. listopada 2017. godine moguće izdavati jedino putem Informacijskog sustava energetske certifikata (IEC). Sustav energetske certifikata služi za izdavanje i pohranu energetske certifikata zgrada, unos podataka o energetske stanju zgrada, prikupljanje, pohranu i upravljanje podacima o zgradama, ovlaštenim osobama za provođenje energetske pregleda i certificiranja zgrada, upravljanje podacima o redovitim pregledima sustava grijanja i hlađenja, podacima o nositeljima obuke te podacima o

neovisnim kontrolorima energetske certifikata, kao i pohranu izvještaja o provedenim energetskim pregledima zgrada i sustavu izvještavanja [191].

Prema podacima iz Nacionalnog informacijskog sustava za gospodarenje energijom, u Republici Hrvatskoj je 2010. godine evidentirano ukupno 13,8 milijuna m² korisne grijane površine zgrada javnog sektora. Kako bi ispunila obvezu obnove 3 % ukupne površine grijane i/ili hladene zgrada u vlasništvu i uporabi središnje vlasti, Hrvatska je do 2020. godine primijenila alternativni pristup, postavljajući cilj ekvivalentnih ušteda od 0,00489 PJ godišnje. Ovaj alternativni pristup nastaviti će se koristiti i u razdoblju do 2030. godine [187].

4.2. Podaci o javnim zgradama za obrazovanje u Republici Hrvatskoj

Energetska svojstva, karakteristike i potrošnja energije zgrada uvelike ovise o razdoblju njihove izgradnje, kao i o postojanju i primjeni propisa o toplinskoj zaštiti. Nedostatak ili nedovoljna regulativa su razlozi zbog kojih značajan broj postojećih zgrada izgrađenih prije nekoliko desetljeća ima znatan utjecaj na okoliš i visoku potrošnju energije. Potrošnja toplinske energije u Republici Hrvatskoj je visoka, s obzirom na to da je najveći broj zgrada izgrađen u razdoblju naglog rasta broja stanovnika i izgradnje zgrada tijekom početka druge polovice 20. stoljeća, konkretno u razdoblju 60-ih, 70-ih i ranih 80-ih godina. Ovo razdoblje podudara se s vremenom kada još uvijek nisu postojali odgovarajući propisi u vezi s uštedom topline i toplinskom zaštitom u zgradama. U kontinentalnoj Hrvatskoj, dominantan je udio javnih zgrada izgrađenih prije i tijekom 70-ih godina 20. stoljeća, prije sustavnog donošenja regulative o toplinskoj zaštiti zgrada što je vidljivo na slici 2 [21].



Slika 2 Broj javnih zgrada u Republici Hrvatskoj prema godini izgradnje [13]

Prema *Dugoročnoj strategiji obnove nacionalnog fonda zgrada do 2050. godine*, površina nestambenih zgrada u RH u 2018. godini činila je 28 % ukupne površine hrvatskog fonda zgrada dok su obrazovne zgrade činile 10 % površine svih nestambenih zgrada [13]. Sličan udio obrazovnih zgrada u ukupnoj površini nestambenih zgrada od 10 % projicira se i za 2030., 2040. te 2050. godinu (Tablica 9).

Tablica 9 Projekcija ukupne površine nestambenih zgrada u 2030., 2040. i 2050. godini [13]

Nestambene zgrade	2030 [m ²]	2040 [m ²]	2050 [m ²]
Uredske	10 309 712	10 831 614	11 082 926
Obrazovne	6 236 465	6 552 169	6 704 190
Hoteli i restorani	4 650 511	4 885 930	4 999 292
Bolnice	3 280 271	3 446 326	3 526 286
Sportske dvorane	462 823	486 252	497 534
Trgovine	12 833 465	13 483 125	13 795 956
Ostalo	24 303 780	25 534 093	26 126 528
Ukupna površina:	62 077 026	65 219 509	66 732 712

Prema Programu energetske obnove zgrada javnog sektora za razdoblje do 2030. godine, zgrade javnog sektora podijeljene su prema namjeni na ukupno devet kategorija [192]:

- obiteljske kuće – SZ1
- zgrade za stanovanje – višestambene zgrade – SZ2
- uredske zgrade – NSZ1
- zgrade za obrazovanje – NSZ2
- zgrade bolnica – NSZ3
- ugostiteljski objekti i hoteli – NSZ4
- druge nestambene zgrade – NSZ5
- sportske dvorane – NSZ6
- trgovine NSZ7
- ostalo NSZ8.

Navedena podjela koristi se i u IEC sustavu [191]. U tablici 10 prikazana je ploština korisne površine grijanog dijela zgrada (A_k) prema namjeni i razdoblju gradnje u m² [192].

Tablica 10 Ploština korisne površine grijanog dijela zgrada (A_k) prema namjeni i razdoblju izgradnje u m^2

[192]

namjena	razdoblje izgradnje									
	sva razdoblja gradnje	≤ 1945	1946-1960	1961-1970	1971-1980	1981-1990	1991-2000	2000-2010	2011-2020	nema podataka
SZ1	6105	1167	0	188	251	0	53	44	94	4308
SZ2	1263152	214957	62582	144306	161629	207193	50606	54182	26272	341426
NSZ1	4358047	977266	267518	253651	358989	255999	157326	174780	42142	1870466
NSZ2	6505629	1275959	630027	875762	1028385	658072	295187	379063	116896	1246279
NSZ3	2241757	531136	158031	208975	333889	323327	41895	105790	5976	532738
NSZ4	115009	1141	5859	0	0	46556	0	0	697	60756
NSZ5	758495	184807	25714	28102	51438	334141	63334	53449	54995	263283
NSZ6	767140	21262	16926	10876	101049	58718	35228	248926	34863	239231
NSZ7	38939	3828	1658	1290	2241	1856	87	3430	0	24549
NSZ8	45254	1300	0	267	9228	4940	637	19276	0	9605
ukupno	16099527	3212823	1168314	1523417	2047099	1590074	644323	1038940	218895	4592642

Iz tablice 10 vidljivo je da je većina zgrada za obrazovanje izgrađena u periodu do 1980. godine dok su zakoni o energetske učinkovitosti i toplinske izolaciji zgrada bili nedovoljni.

U tablici 11 prikazana je specifična godišnja potrebna toplinska energija za grijanje (kWh/m^2god) prema namjeni i razdoblju izgradnje zgrade za kontinentalnu Hrvatsku [192].

Tablica 11 Specifična godišnja potrebna toplinska energija za grijanje (kWh/m^2god) prema namjeni i razdoblju izgradnje zgrade za kontinentalnu Hrvatsku [192]

namjena	≤ 1945	1946-1960	1961-1970	1971-1980	1981-1990	1991-2000	2000-2010	2011-2020
SZ1	220	220	220	160	160	160	80	80
SZ2	150	150	150	110	110	110	80	80
NSZ1	158	170	171	189	173	108	78	65
NSZ2	171	163	158	142	128	118	82	64
NSZ3	191	173	196	157	157	137	97	80
NSZ4	201	178	214	217	171	35	100	74
NSZ5	259	225	246	231	218	160	125	133
NSZ6	202	225	151	209	207	134	148	80
NSZ7	173	201	200	227	168	107	101	65

NSZ8	-	-	-	-	-	-	-	-
------	---	---	---	---	---	---	---	---

Iz tablice 11 vidljivo je da zgrade izgrađene do 1980., kojih je većina u obrazovnim zgradama, zahtijevaju puno veću potrošnju specifične godišnje potrebne toplinske energije za grijanje, u odnosu na novije zgrade.

Neki od najčešćih izazova u implementaciji upravljanja energijom u školama obuhvaćaju sljedeće [193]:

- Školske zgrade često su u vlasništvu regionalnih ili općinskih uprava, a ravnatelji škola nemaju ovlasti za donošenje ključnih odluka dok je komunikacija između škola i nadležnih tijela u vezi s energetsom učinkovitošću školskih zgrada često nedovoljna.
- Nedostatak općeg i tehničkog znanja među školskim osobljem.
- Ograničeni ljudski resursi u školama, posebno nedostatak vremena.
- Niska motivacija osoblja i učenika, često uz nedostatak financijskih poticaja za školsko osoblje.
- Opća slabija motivacija s obzirom na proračunsku organizaciju škola.
- Teški uvjeti za učinkovito upravljanje djecom ili mladima.

S druge strane, kao načini implementacije učinkovitog upravljanja energijom u školama navode se [193]:

- Aktivna uključenost i odgovornost ravnatelja škole.
- Razvoj strategija i planova za energetska učinkovitost, gdje lokalne vlasti mogu pružiti centralizirano rješenje za više škola ili općinskih zgrada, ili se fokusirati na lokalne, izravne inicijative unutar svake škole.
- Uspostava dobre komunikacije, koja obuhvaća unutarnju dimenziju (između ravnatelja, osoblja i učenika) i vanjsku dimenziju (između ravnatelja škole, donositelja odluka i lokalnih vlasti).

Prema *Priručniku za energetska certificiranje zgrada iz 2010. godine*, postojeće zgrade u Republici Hrvatskoj se mogu podijeliti u ovisnosti o zakonodavnom okruženju prema starosti i vrsti gradnje u sljedeće grupe [194]:

- zgrade građene prije 1940. godine,
- zgrade građene u razdoblju od 1940. do 1970. godine,
- zgrade građene u razdoblju od 1970. do 1987. godine,
- zgrade građene u razdoblju od 1987. do 2006. godine i
- novogradnja usklađena s Tehničkim propisom [195-197].

Glavne karakteristike izgradnje prema razdoblju navedene su u tablici 12.

Tablica 12 Razdoblja i karakteristike izgradnje zgrada u RH [194, 198]

Razdoblje izgradnje	Karakteristike izgradnje
Prije 1940. godine	Ovo razdoblje karakterizira intenzivno korištenje tradicionalnih metoda gradnje i materijala te nedostatak toplinske zaštite. Zgrade u pravilu imaju masivnu konstrukciju od opeke ili kamena gdje debljine zida iznose 25, 38 ili 50 cm, a ponekad i više. Podrumski prostori predstavljali su uglavnom pomoćne negrijane prostorije. Stropovi su se izvodili od drveta, opeke, kamena ili betonskih elemenata. Podovi su se izvodili na sloju nabijene zemlje. S obzirom na debljinu konstrukcije ovoga perioda, zgrade nisu imale tako velike toplinske gubitke kao u sljedećem periodu.
Od 1940. do 1970. godine	Kao i prethodno, ovo razdoblje karakterizira intenzivno korištenje tradicionalnih metoda gradnje i materijala te nedostatak toplinske zaštite. Ipak, u ovome se razdoblju pojavljuju novi materijali te statički laganije i tanje konstrukcije bez toplinske izolacije i velike ostakljene površine s lošim toplinskim karakteristikama. Razdoblje je karakteristično prema ubrzanoj izgradnji koja danas predstavlja najveći problem u kontekstu energetske potrošnje.
Od 1970. do 1987. godine	U ovome razdoblju česta je izgradnja vitkih skeletnih konstrukcija ili poprečnih betonskih nosivih zidova te su česti predgotovljeni betonski parapeti. Iako se u ovom periodu pojavljuju prvi propisi vezani uz toplinsku zaštitu te oskudno korištenje toplinske izolacije, također ga karakterizira izgradnja statički vitkih i tankih konstrukcija, ostakljenih površina te zgrada koje zapravo imaju vrlo loše toplinske karakteristike. Armiranobetonski zidovi izvodili su se u minimalnim debljinama od 16 i 18 cm, dok su se zidane konstrukcije izvodile od šuplje blok opeke od 19 cm ili pune od 25 cm.
Od 1987. do 2006. godine	U ovom se razdoblju počinju koristiti toplinske zaštite kao što su kamena vuna i ekspanzirani polistiren u debljinama 4,5,6 za vanjske zidove te 8 do 12 cm za kose krovove, no bitnog napretka u toplinskoj zaštiti zgrada u ovome razdoblju nema. U primorskom dijelu Hrvatske često se koristila toplinska žubka bez dodatne toplinske izolacije.
Novogradnja od 2006. godine	S obzirom na uvođenje Tehničkog propisa o uštedi toplinske energije i toplinskoj zaštiti u zgradama (NN 79/05) od 1. srpnja 2005. godine. Energetska učinkovitost i

	održiva gradnja postaje prioritet. Pri projektiranju počinje se razmišljati o odabiru lokacije, orijentacije i oblika kuće, zahtijeva se visoka razina toplinske zaštite cijele vanjske ovojnice zgrade te se traži smanjenje utjecaja toplinskih mostova na minimum.
--	---

4.3. Prikupljanje podataka o geometrijskim, materijalnim i uporabnim karakteristikama školskih zgrada te o njihovoj potrošnji energije, energenata i vode

U prosincu 2023. godine za potrebe ovog istraživanja upućen je službeni dopis prema APN-u i ISGE-u kojim se tražilo odobrenje pristupa ISGE sustavu. Od ISGE-a odobren je pristup podacima za osnovne i srednje škole za području Osječko-baranjske županije, a navedeni podaci su sljedeći:

- Opći podaci (naziv objekta, ISGE šifra, vrsta objekta, županija, grad);
- Podaci o konstrukciji i restauraciji (godina završetka izgradnje i godina zadnje obnove);
- Korištenje zgrade (broj zaposlenika, broj korisnika, broj radnih dana u tjednu, broj radnih dana u godini, broj radnih sati u radnom danu),
- Osnovne dimenzije zgrade (ploština bruto podne površine zgrade [m^2], ploština korisne površine zgrade A_k [m^2], oplošje grijanog dijela zgrade A [m^2], obujam grijanog dijela zgrade V_e [m^3], broj etaža)
- Podaci o sustavu grijanja (ukupno instalirana snaga ogrjevnih tijela – radijatora [kW], ukupno instalirana snaga ostalih ogrjevnih tijela [kW] i ukupna instalirana toplinska snaga ogrjevnih tijela [kW]);
- Podaci o sustavu hlađenja (ukupna instalirana rashladna snaga rashladnih tijela [kW]);
- Računski koeficijenti (faktor oblika zgrade f_o [m^{-1}], koeficijent transmisijskog topl. gubitka H_T [W/K] i udio ploštine prozora u ukupnoj ploštini pročelja f [%]);
- Podaci o korištenim energentima (godišnja potrošnja energije u kWh, godišnja emisija CO_2).

Za korištenje ISGE sustava i preuzimanje podataka iz njega, bilo je potrebno polaziti „ISGE-onicu za korištenje Nacionalnog informacijskog sustava za gospodarenje energijom ISGE“ u ulozi Energetski menadžer koja je završena u prosincu 2023. godine. Edukaciju je u skladu s obvezama iz Pravilnika o sustavnom gospodarenju energijom u javnom sektoru proveo Odjel za sustavno gospodarenje energijom i ISGE Agencije za pravni promet i posredovanje nekretninama.

Iz pregleda podataka u ISGE, bilo je vidljivo da se u njemu ne nalaze svi podaci iz energetske certifikata škola iz razloga što količina unešenih podataka i razina detaljnosti u ISGE ovisi od korisnika do korisnika odnosno osobe koja je u školi zadužena za unos podataka. Kao što je već prethodno navedeno na IEC dostupni su samo oni energetske certifikati koji su izdani od 1. listopada 2017. godine putem IEC-a [191]. Stoga je u prosincu 2023. godine upućen zahtjev MGIPU s molbom za ustupljanje energetske certifikata školskih zgrada u Osječko-baranjskoj županiji čiji se energetske certifikati ne nalaze u IEC-u odnosno onih koji su izdani prije navedenog datuma. Podaci na temelju kojih je izvađen uzorak iz baze odnosno koji su bili zatraženi su:

- 1.) Podaci o zgradi (nova, postojeća ili rekonstrukcija)
- 2.) Ploština korisne površine grijanog dijela zgrade A_k
- 3.) Građevinska (bruto) površina zgrade
- 4.) faktor oblika f_o
- 5.) Godina izgradnje/rekonstrukcije
- 6.) k.č.br.
- 7.) Specifična godišnja potrebna toplinska energija za grijanje
- 8.) Specifična godišnja primarna energija
- 9.) Specifična godišnja emisija CO_2
- 10.) Datum izdavanja certifikata
- 11.) Koeficijent transmisivnog toplinskog gubitka
- 12.) Koeficijent prolaska topline za sve građevne dijelove
- 13.) Podaci o termotehničkim sustavima
- 14.) Godišnja potrebna toplinska energija za grijanje
- 15.) Godišnja primarna energija.

Za dio škola podaci su i dalje bili nedostajući te se posegnulo i za korištenjem Godišnjeg plana i programa rada koji se donosi na osnovi nastavnog plana i programa i školskog kurikulumu, a donosi ga školski odbor do 30. rujna tekuće školske godine. Godišnji planovi i programi rada dostupni su na internet stranicama škola, a sadržavaju aktualne podatke o broju nastavnika, broju učenika, korisnoj površini školske zgrade, a i podatak o godini izgradnje školske zgrade.

Djelovanje osnovnih i srednjih škola uređeno je *Državnim pedagoškim standardom osnovnoškolskog sustava odgoja i obrazovanja* (NN 63/2008) [199] te *Državnim pedagoškim standardom srednjoškolskog sustava odgoja i obrazovanja* (NN 63/2008) [200]. Prema tome, osnovna škola je odgojno-obrazovna ustanova u kojoj se provodi odgoj i obrazovanje, a ima najmanje po jedan razredni odjel od I. do VIII.

razreda dok je područna škola odgojno-obrazovna podružnica škole, smještena izvan sjedišta matične škole, a s kojom je programski i kadrovski povezana. Ustrojava se ako upisnom kvotom osigurava broj učenika za najmanje po jedan razredni odjel od I. do IV., odnosno od V. do VIII. razreda te ako ispunjava *Standard za obavljanje djelatnosti* [199].

Analizirane škole, osim matičnih škola, podrazumijevaju i područne škole s obzirom na to da svaka područna škola ima svoju zasebnu zgradu, a predmet analize je zasebna zgrada. Također, potrebno je naglasiti da određene škole dijele zgradu (npr. Tehnička škola i prirodoslovna gimnazija R. Boškovića i Medicinska škola Osijek) te su zajedno i analizirane s obzirom na to da imaju zajedničku potrošnju energije, a karakteristike su im zbrojene dok određene škole imaju dvije razdvojene zgrade (npr. Ekonomska i upravna škola Osijek) te su stoga zasebno i analizirane. Popis analiziranih osnovnih i srednjih škola na području Osječko-baranjske županije nalazi se u tablici 13.

Tablica 13 Popis analiziranih osnovnih i srednjih škola na području Osječko-baranjske županije

R. br.	Naziv škole
1	Ekonomska i upravna škola Osijek, Bosendorferova
2	Ekonomska i upravna škola Osijek, Trg sv. Trojstva
3	Trgovačka i komercijalna škola Davor Milas
4	II. gimnazija Osijek
5	Isusovačka klasična gimnazija s pravom javnosti Osijek
6	III. gimnazija Osijek, prirodoslovnomatematička
7	Poljoprivredna i veterinarska škola Osijek
8	Graditeljsko geodetska škola Osijek
9	Glazbena škola Franje Kuhača Osijek
10	Obrtnička škola Osijek
11	Tehnička škola i prirodoslovna gimnazija R. Boškovića i Medicinska škola Osijek
12	I. gimnazija Osijek
13	Ugostiteljsko turistička škola Osijek
14	Škola primjenjene umjetnosti i dizajna Osijek
15	OŠ Bijelo Brdo
16	PŠ Aljmaš
17	PŠ Erdut
18	OŠ Petrijevci
19	OŠ Laslovo
20	PŠ Šodolovci
21	OŠ Ernestinovo
22	OŠ Antunovac
23	PŠ Ivanovac
24	OŠ Bratoljuba Klaića Bizovac
25	PŠ Cret

26	PŠ Samatovci
27	PŠ Satnica
28	PŠ Brođanci
29	PŠ Habjanovci
30	OŠ IB Mažuranić Koška
31	PŠ Niza
32	PŠ Ledenik
33	PŠ Lug Subotički
34	PŠ Topoline
35	OŠ IB Slovaka Jelisavac
36	PŠ Lađanska
37	PŠ Breznica Našička
38	OŠ Dalj
39	Srednja škola Dalj
40	PŠ Ivanovci
41	PŠ Harkanovci
42	OŠ "Dr. Franjo Tuđman" Beli Manastir
43	OŠ Šećerana
44	PŠ Luč
45	PŠ Branjin Vrh
46	PŠ Kneževo
47	OŠ Popovac
48	PŠ Branjina
49	PŠ Duboševica
50	OŠ Draž
51	PŠ Topolje
52	PŠ Batina
53	OŠ Zmajevac
54	PŠ Novi Beždan
55	PŠ Kotlina
56	PŠ Suza
57	OŠ Kneževi Vinogradi
58	PŠ Grabovac
59	PŠ Karanac
60	PŠ Petlovac
61	PŠ Baranjsko Petrovo Selo
62	PŠ Torjanci
63	PŠ Bolman
64	OŠ Jagodnjak
65	OŠ Čeminac
66	PŠ Kozarac
67	OŠ Darda
68	PŠ Uglješ
69	PŠ Mece
70	OŠ Bilje

71	PŠ Kopačevo
72	OŠ Lug
73	PŠ Vardarac
74	Ekonomska škola B. Radić Đakovo i srednja strukovna škola A. Horvata
75	OŠ Budrovci
76	PŠ Đurđanci
77	OŠ "I. G. Kovačić" Đakovo – predmetna nastava
78	OŠ "I. G. Kovačić" Đakovo – razredna nastava
79	OŠ J. A. Čolnica Đakovo
80	PŠ Kuševac
81	OŠ "Vladimir Nazor" Đakovo
82	PŠ Ivanovci Gorjanski
83	PŠ Đakovački Pisak
84	Gimnazija A. G. Matoša Đakovo
85	PŠ Vučevci
86	OŠ Viškovci
87	OŠ "J. Kozarca" Semeljci
88	PŠ Forkuševci
89	PŠ Koritna
90	PŠ Kešinci
91	OŠ Milka Cepelića, Vuka
92	PŠ Beketinci
93	PŠ Široko Polje
94	OŠ Mate Lovraka Vladislavci
95	OŠ "I. B. Mažuranić" Strizivojna
96	PŠ Soljak
97	OŠ "J. J. Strossmayera" Trnava
98	PŠ Lapovci
99	PŠ Hrkanovci
100	PŠ Kondrić
101	PŠ Dragotin
102	OŠ Đakovački Selci
103	OŠ "Matija Gubec" Piškorevci
104	PŠ Novi Perkovci
105	OŠ Drenje
106	PŠ Pridvorje
107	PŠ Mandićevac
108	PŠ Slatinik Drenjski
109	PŠ Kućanci Đakovački
110	OŠ Satnica Đakovačka
111	PŠ Gašinci
112	OŠ Gorjani
113	PŠ Tomašanci
114	PŠ Paljevina

115	PŠ Potnjani
116	PŠ Bračevci
117	OŠ "Josip Kozarac" Josipovac Punitovački
118	PŠ Punitovci
119	PŠ Jurjevac Punitovački
120	PŠ Čepinski Martinci
121	OŠ Vladimir Nazor
122	OŠ Miroslava Krleže Čepin
123	PŠ Poganovci
124	OŠ Hinka Juhna Podgorač
125	PŠ Stipanovci
126	PŠ Razbojište
127	PŠ Velimirovac
128	PŠ Seona
129	OŠ Dore Pejačević Našice
130	PŠ Vukojevci
131	OŠ kralja Tomislava Našice
132	PŠ Markovac Našički
133	PŠ Gradac Našički
134	PŠ Klokočevci
135	Srednja škola I. Kršnjavoga Našice
136	OGŠ Kontesa Dora Pejačević
137	OŠ "J. J. Strossmayera" Đurđenovac
138	PŠ Pribiševeci
139	PŠ Šaptinovci
140	PŠ Bokšić
141	PŠ Bokšić Lug
142	PŠ Beljevina
143	Srednja škola Josipa Kozarca Đurđenovac
144	OŠ "V. Nazora" Feričanci
145	PŠ Donja Motičina
146	PŠ Krčenik
147	PŠ Podravska Moslavina
148	PŠ Kapelna
149	OŠ "A. Starčević" Viljevo
150	OŠ "A. Harambašić" Donji Miholjac
151	Osnovna glazbena škola "A. Harambašić" Donji Miholjac
152	Srednja škola Donji Miholjac
153	PŠ Ivanovo
154	OŠ "M. Gubec" Magadenovac
155	PŠ Kućanci
156	PŠ Lacići
157	PŠ Šljivoševci
158	PŠ Beničanci
159	PŠ Rakitovica

160	PŠ Golinci
161	PŠ Radikovci
162	PŠ Miholjački Poreč
163	OŠ "M. P. Katančića" Valpovo
164	PŠ Bocanjevci
165	PŠ Nard
166	OŠ Ladimirevci
167	Srednja škola Valpovo
168	PŠ Šag
169	OŠ Ivana Kukuljevića Belišće
170	OŠ Hrvatski Sokol Podgajci Podravski
171	PŠ Črnkovci
172	PŠ Veliškovci
173	PŠ Vinogradci
174	PŠ Marijanci
175	PŠ Čamagajevci
176	PŠ Vrbica
177	PŠ Mrzović
178	OŠ Franje Krežme Osijek
179	OŠ Dobriša Cesarić Osijek
180	OŠ Vladimira Becića Osijek
181	OŠ Svete Ane Osijek
182	OŠ Grigor Vitez Osijek
183	OŠ Mladost Osijek
184	OŠ Tin Ujević, Osijek
185	OŠ Antuna Mihanovića Osijek
186	OŠ August Šenoa Osijek
187	OŠ Ivana Filipovića Osijek
188	OŠ Retfala Osijek
189	OŠ Vijenac Osijek
190	OŠ Jagoda Truhelka Osijek
191	OŠ Ljudevita Gaja Osijek
192	OŠ Cvjetno
193	OŠ Sarvaš
194	OŠ Višnjevac
195	OŠ Josipovac

Važno je naglasiti da su unatoč svim uložnim naporima i prikupljanjima podataka s nekoliko različitih strana, određeni podaci ipak bili za određene škole nedostajući, te je za razvoj svakog od modela i za razvoj sustava procjene stanja primijenjen različit uzorak iz ukupnog uzorka s obzirom na dostupnost podataka.

5. RAZVOJ MODELA ZA PROCJENU POTROŠNJE ENERGIJE, ENERGENATA I VODE I USPOREDBA STVARNE I PRORAČUNSKE POTROŠNJE ENERGIJE

5.1. Razvoj modela za procjenu potrošnje električne energije

5.1.1. Prikupljanje i analiza podataka za razvoj modela procjene potrošnje električne energije

Podaci su dobiveni iz ISGE baze podataka za osnovne i srednje škole Osječko-baranjske županije u Hrvatskoj. Dobiveni podaci obuhvaćaju nekoliko parametara koji utječu na potrošnju energije, prvenstveno vezanih uz karakteristike zgrade, a te su vrijednosti korištene kao ulazni podaci u modelima. Modeli su uključivali jedan parametar, prosječnu godišnju potrošnju električne energije mjerenu u kWh/god, kao izlaznu varijablu. Prikupljeni podaci obuhvatili su potrošnju električne energije 149 školskih zgrada u razdoblju od 2013. do 2023. godine. Kako bi se proces pojednostavio, podaci su uređeni u Microsoft Excel radnim knjigama [201], koje su kompatibilne s TIBCO Statistica® 14.1.0 [202], softverom korištenim za razvoj modela.

Prvo je bilo potrebno odrediti ulazne (nezavisne) varijable koje utječu na potrošnju električne energije u školama. Pregled prethodnih istraživanja na ovu temu korišten je za identificiranje najznačajnijih ulaznih varijabli, pri čemu je prosječna godišnja potrošnja električne energije bila izlazna varijabla. Identificirane značajne ulazne varijable za procjenu potrošnje električne energije školskih zgrada u prikazane su u tablici 14 s relevantnim istraživanjima u kojima su također korištene.

Tablica 14 Identificirane značajne ulazne varijable za razvoj modela procjene potrošnje električne energije

Ulazna varijabla	Opis	Oznaka	Mjerna jedinica	Korišteno u
Ukupan broj korisnika (djelatnici i učenici)	Predstavlja ukupan broj osoba koje koriste zgradu (engl. <i>Total Number of Users</i>)	<i>TNU</i>	broj korisnika	[113, 130, 140, 203-206]

Ukupna korisna površina	Ukupna površina unutar zgrade koja se grije/hladi	A_k	m ²	[113, 130, 140, 203, 205-207]
Obujam zgrade	Ukupni volumen prostora unutar zgrade	V_e	m ³	[102, 203, 204]

Svaka od ovih varijabli odabrana je na temelju svog dokazanog utjecaja na potrošnju energije u zgradama u istraživanjima navedenim u tablici 14. Ukupan broj korisnika (TNU) utječe na potrošnju energije kroz povećane uporabne zahtjeve, dok ukupna korisna površina (A_k) i grijani obujam (V_e) utječu na količinu energije potrebnu za regulaciju temperature.

Također, nakon određivanja ulaznih varijabli, bilo je potrebno odrediti izlaznu (zavisnu) varijablu, koja je prikazana u tablici 15.

Tablica 15 Izlazna varijabla za razvoj modela procjene potrošnje električne energije u školskim zgradama

Izlazna varijabla	Oznaka	Mjerna jedinica
Prosječna godišnja potrošnja električne energije (engl. <i>Annual Electrical Energy Consumption</i>)	<i>AEC</i>	kWh/god

Tablica 16 prikazuje deskriptivnu statistiku ulaznih i izlaznih varijabli modela procjene potrošnje električne energije.

Tablica 16 Deskriptivna statistika ulaznih i izlaznih varijabli modela procjene potrošnje električne energije


Vrsta varijable	Varijabla	N	Aritmetička sredina	Minimum	Maksimum	Standardna devijacija
Ulazna	<i>TNU</i>	149	132,96	3,00	894,00	176,21
	A_k	149	1107,71	37,70	6210,26	1316,78
	V_e	149	4435,26	113,10	25935,40	5357,29
Izlazna	<i>AEC</i>	149	13624,54	393,39	59566,18	15486,72

Deskriptivna statistika iz tablice 16 prikazuje pregled distribucije svake varijable:

- TNU ima raspon od 3 do 894, s prosjekom od 132,96 i značajnom standardnom devijacijom od 176,21, što ukazuje na veliku varijabilnost u broju korisnika među uzorcima.
- A_k se kreće od 37,70 do 6210,26, s prosječnom ukupnom površinom od 1107,71, uz značajnu standardnu devijaciju od 1316,78, što ukazuje na veliku varijabilnost unutar skupa podataka.
- V_e pokazuje širok raspon vrijednosti od 113,10 do 25935,40, dok je prosječni grijani volumen 4435,26, uz značajnu standardnu devijaciju od 5357,29, što ukazuje na velike razlike među opažanjima.
- AEC se kreće od 393,39 do 59566,18, s prosječnom potrošnjom od 13624,54 i značajnom standardnom devijacijom od 15486,72, što odražava veliku raznolikost potrošnje među uzorkovanim školskim zgradama.

Prisutnost malih područnih škola i većih gradskih škola vjerojatno utječe na uočenu varijabilnost u potrošnji električne energije u skupu podataka. Takve razlike u veličini i infrastrukturi obrazovnih ustanova mogu dovesti do značajnih razlika u potrošnji energije. Male područne škole imaju manji broj učenika, manje zgrade i jednostavnije sustave grijanja, ventilacije i klimatizacije u usporedbi s većim gradskim školama, što rezultira nižom prosječnom potrošnjom energije. S druge strane, veće gradske škole posjeduju veće prostore, uključujući veće učionice i administrativne prostore koji zahtijevaju više energije. Stoga, širok raspon vrijednosti potrošnje električne energije u skupu podataka odgovara razlikama u karakteristikama i veličini škola uključenih u analizu, naglašavajući važnost razmatranja ovih čimbenika prilikom analize obrazaca potrošnje energije i razvoja prediktivnih modela.

Pearsonov koeficijent linearne korelacije (r), nazvan po Karlu Pearsonu, mjeri snagu i smjer linearne veze između dviju varijabli. On pokazuje koliko je vjerojatno da promjena jedne varijable odgovara specifičnoj promjeni druge varijable, bilo u izravnom ili obrnuto proporcionalnom odnosu. Njegova vrijednost kreće se od -1 preko 0 pa do +1 [208]. Na slici 3 prikazana je pozitivna korelacija, negativna te primjer bez korelacije, redom.



Slika 3 Pozitivna korelacija, negativna korelacija, bez korelacije [209]

Ključno je ispitati korelaciju između izlazne varijable i ulaznih varijabli jer omogućuje istraživanje odnosa između izlaza modela, odnosno potrošnje električne energije u školama i ulaznih varijabli modela. Važno je napomenuti da pozitivna vrijednost označava pozitivnu korelaciju, što znači da povećanje jedne varijable dovodi do povećanja druge varijable [210]. Nasuprot tome, negativna vrijednost označava negativnu korelaciju, što znači da povećanje jedne varijable smanjuje drugu. Međutim, u ovom slučaju ne postoje takvi odnosi. Sve korelacije su vrlo značajne, što je naznačeno njihovim visokim vrijednostima i crvenim oznakama. Crveno označene korelacije imaju razinu značajnosti od $p < 0,05$. Tablica 17 prikazuje korelacije ulaznih varijabli s izlaznom varijablom potrošnje energije (kWh/god).

Tablica 17 Korelacije ulaznih varijabli s izlaznom varijablom AEC

Varijabla	Korelacija s izlaznom varijablom AEC
TNU	0,870730
A_k	0,943930
V_e	0,895643

Iz tablice je vidljivo sljedeće:

- TNU ima korelacijski koeficijent od 0,870730 s AEC, što sugerira snažnu pozitivnu korelaciju. To implicira da su promjene u TNU usko povezane s promjenama u AEC, naglašavajući značajan utjecaj TNU na potrošnju električne energije.
- A_k pokazuje još viši korelacijski koeficijent od 0,943930 s AEC, što ukazuje na još jaču pozitivnu korelaciju od TNU . To sugerira da A_k ima posebno izražen utjecaj na AEC, što potencijalno ukazuje na njegovu ključnu ulogu u određivanju potrošnje električne energije.

- V_e također pokazuje relativno visok korelacijski koeficijent od 0,895643 s AEC , što ukazuje na snažnu pozitivnu korelaciju. To sugerira da su varijacije u V_e usko povezane s promjenama u AEC , naglašavajući važnost V_e u utjecaju na potrošnju električne energije.

Početni skup podataka podijeljen je u dva skupa nasumično – skup za treniranje (engl. *training set*), koji je korišten za izradu ili razvoj modela, i skup za validaciju (engl. *validation set*), koji je korišten isključivo za procjenu pogrešaka razvijenih modela. U skupu za trening nasumično je odabrano 105 školskih zgrada, što čini 70,5 % od ukupno 149 školskih zgrada, a u skupu za validaciju nalazi se 44 školske zgrade ili 29,5 % od ukupnog broja. Slični omjeri korišteni su i u [211, 212].

5.1.2. Razvoj modela procjene potrošnje električne energije pomoću višestruke linearne regresije

Regresijska analiza omogućuje definiranje odnosa između neovisnih i zavisnih varijabli, analizu varijabli u pogledu njihove dostupnosti, relevantnosti i prikupljanja, te izradu matematičkih modela za predviđanje. Regresijska analiza je tehnika za razvoj modela koja koristi statističku analizu ključnih varijabli i povijesnih podataka [213].

Obično se nastoji utvrditi uzročni učinak jedne varijable na drugu. Da bi se to utvrdilo, prvo se prikupljaju podatci o relevantnim varijablama i koristi se regresija kako bi se procijenio kvantitativni učinak uzročnih varijabli na varijablu na koju one utječu [214].

Svaka primjena regresijske analize mora razlikovati uloge dviju kvantitativnih varijabli. Ona koju želimo predvidjeti ili za koju vjerujemo da je pod utjecajem naziva se zavisna ili izlazna varijabla, a ona koju ćemo koristiti kao osnovu za predviđanje ili za koju vjerujemo da uzrokuje neku promjenu naziva se nezavisna ili ulazna varijabla. Tradicionalno se zavisna varijabla označava kao y , a nezavisna varijabla kao x [215].

Regresijska analiza možda je najčešće korištena tehnika za izvođenje zaključaka iz eksperimentalnih podataka. Osnovna ideja je prilagoditi funkciju koja blisko predstavlja trend u podacima koja se zatim može koristiti za predviđanje uključenih varijabli. Prilagođavanje funkcije podacima putem regresijske analize nije uvijek lako, osobito ako podaci pokazuju varijacije koje se ne mogu okarakterizirati standardnim funkcijama, kao što su polinomijalne, eksponencijalne ili logaritamske. Najlakši oblik regresijske analize je jednostavna linearna regresija. Jednostavna linearna regresija odnosi se na prilagođavanje ravne linije podacima. Prilagodba se uglavnom izvodi tehnikom koja se zove prilagodba najmanjih kvadrata [215].

Višestruka linearna regresija je matematička tehnika koja se koristi za modeliranje odnosa između više nezavisnih varijabli i jedne zavisne varijable. Cilj ove analize je utvrđivanje koliko svaka od nezavisnih varijabli doprinosi predviđanju ili objašnjenju varijacije zavisne varijable [216]. Matematički model višestruke regresije prikazuje se kao jednadžba koja uključuje konstantu i koeficijente za svaku nezavisnu varijablu. Ovi koeficijenti pokazuju koliki je utjecaj svake varijable na zavisnu varijablu. Tijekom analize procjenjuju se ovi koeficijenti te se testira statistička značajnost modela kako bi se utvrdilo koliko je predviđanje precizno i koji su faktori najvažniji.

Uobičajeni oblik jednadžbe višestruke linearne regresije s k neovisnih varijabli je [217]:

$$\hat{Y} = a + b_1 \cdot X_1 + b_2 \cdot X_2 + \dots + b_k \cdot X_k \quad (1)$$

gdje je:

- $\hat{Y}$ zavisna varijabla,
- a slučajna pogreška,
- $b_{1...k}$ regresijski koeficijenti i
- $X_{1...n}$ nezavisne varijable.

Najbolji razvijeni model pomoću višestruke linearne regresije za zavisnu varijablu *AEC*, koja predviđa prosječnu godišnju potrošnju električne energije, ima sljedeći oblik:

$$AEC = 440,89 + 26,06 TNU + 6,07 A_k + 0,66 V_e [kWh/god] \quad (2)$$


gdje je:

- TNU : Nezavisna varijabla koja predstavlja ukupan broj korisnika, uključujući djelatnike i učenike (broj),
- A_k : Nezavisna varijabla koja predstavlja ukupnu korisnu površinu zgrade (m^2),
- V_e : Nezavisna varijabla koja predstavlja obujam zgrade (m^3).

5.1.3. Razvoj modela procjene potrošnje električne energije pomoću neuronske mreže

Za razvoj modela korišten je MLP tip umjetne neuronske mreže. To je vrsta neuronske mreže s više slojeva međusobno povezanih čvorova [218]. Ovi čvorovi obrađuju informacije i uče iz podataka primjenjujući težine i funkcije aktivacije. Cilj MLP-a je smanjiti razlike između vrijednosti koje model

izračunava i željenih ciljanih vrijednosti. Težine se prilagođavaju kako bi se smanjile pogreške ako mreža daje netočan odgovor ili ako pogreške premaše unaprijed određeni prag [219]. Smanjenje pogrešaka povećava vjerojatnost da će budući odgovori mreže biti točni. Tijekom procesa učenja, mreža prikazuje skupove podataka koji sadrže parove željenih ciljeva i ulaznih uzoraka sukcesivno. Algoritam učenja MLP-a sastoji se od dva koraka: jedan za unaprijedno propagiranje i drugi za povratno propagiranje [220]. Slika 4 prikazuje arhitekturu optimalno odabranog modela.



Slika 4 Arhitektura optimalno odabranog modela neuronske mreže (MLP 3-5-1) za razvoj modela procjene potrošnje električne energije

Arhitektura MLP-a odnosi se na broj slojeva i broj čvorova u svakom sloju. U ovom slučaju, oznaka 3-5-1 označava sljedeće:

- 3: Ulazni sloj ima tri čvora, a ti čvorovi predstavljaju značajke ili varijable koje se unose u mrežu.
- 5: Skriveni sloj ima pet skrivenih čvorova, a ovaj sloj obavlja glavnu obradu informacija i učenje unutar mreže.
- 1: Postoji izlazni sloj s jednim čvorom, a taj čvor predstavlja predikciju ili izlaznu vrijednost mreže.

5.1.4. Usporedba točnosti razvijenih modela procjene potrošnje električne energije

Pronalaženje stvarnih vrijednosti očekivanih (procijenjenih) ishoda modela odnosno stupnja u kojem se vrijednosti zavisnih varijabli mogu predvidjeti je ključno [221]. Reprezentativnost, ili sposobnost modela da koristi podskup nezavisnih varijabli za objašnjavanje promjena u zavisnoj varijabli, procjenjuje se s pomoću apsolutnih i relativnih metrika. Ovi indikatori proizlaze iz raspodjele odstupanja vrijednosti zavisne varijable od njezinih predviđenih i aritmetičkih srednjih vrijednosti [222]. Za procjenu točnosti razvijenog modela procjene i omogućavanja usporedbe s drugim modelima s različitim parametrima, koriste se različite statističke tehnike za procjenu pogreške predviđanja.

Za procjenu pogreške predviđanja razvijenih modela korišteni su sljedeći koeficijenti: srednja apsolutna postotna pogreška (engl. *Mean Absolute Percentage Error* (MAPE)), koeficijent determinacije (R^2), srednja kvadratna pogreška (engl. *Mean Square Error* – MSE), korijen srednje kvadratne pogreške (engl. *Root Mean Square Error* – RMSE) i koeficijent varijacije korijena srednje kvadratne pogreške (engl. *Coefficient of the Variation of the Root Mean Square Error* – CVRMSE). Za razliku od većine metričkih pogrešaka, MAPE nema strogu gornju granicu. Razlog tome je što uključuje uzimanje apsolutne vrijednosti postotne pogreške. Koeficijent determinacije R^2 bliži 1 označava da je predikcijski model reprezentativniji [223]. Općenito, manji MSE je poželjan jer znači da su predviđanja modela, u prosjeku, bliža stvarnim vrijednostima. Suprotno tome, visok MSE sugerira da su predviđanja modela dosljedno udaljena od stvarnih vrijednosti [224]. Uobičajeno se za CVRMSE koristi gornja granica od 30 % za mjerenje reprezentativnosti [225].

Uvjet za razmatranje modela bio je koeficijent determinacije R^2 veći od 0,7 te je usvojena gornja granica koeficijenta varijacije korijena srednje kvadratne pogreške (CVRMSE) od 30 % odnosno modeli čija vrijednost CVRMSE prelazi granicu od 30 % nisu uzeti u obzir za daljnje razmatranje [226]. Također, korigirani koeficijent determinacije (adj. R^2) primjenjuje se kod malog uzorka ($N < 30$) te iz toga razloga nije računat. Izrazi korišteni za izračun statističkih tehnika za procjenu pogreške predviđanja prikazani su u tablici 18.

Tablica 18 Izrazi za izračun statističkih tehnika za procjenu pogreške predviđanja

Red. br.	Koeficijent	Izraz	Izvor
1	R^2	$R^2 = 1 - \frac{\sum_{t=1}^n (y_i - \hat{y}_i)^2}{\sum_{t=1}^n (y_i - \bar{Y})^2}$	[217]

2	MSE	$MSE = \frac{1}{n} \sum_{t=1}^n (y_i - \hat{y}_i)^2$	[227]
3	RMSE	$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_i - \hat{y})^2}$	[228]
4	CVRMSE	$CVRMSE = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (y_i - \hat{y})^2}}{\bar{Y}} \cdot 100(\%)$	[229]
5	MAPE	$MAPE = \frac{1}{n} \sum_{t=1}^n \left \frac{(y_i - \hat{y}_i)}{y_i} \right \cdot 100(\%)$	[230]
gdje je: • y_i stvarne vrijednosti zavisne varijable, • $\hat{y}_i$ predviđene ili očekivane vrijednosti zavisne varijable • $\bar{Y}$ aritmetička sredina zavisne varijable.			

Tablica 19 prikazuje vrijednosti prethodno spomenutih koeficijenata za procjenu pogreške predviđanja razvijenih modela u skupu podataka za trening modela.

Tablica 19 Točnosti razvijenih modela procjene potrošnje električne energije za skup podataka za trening

Red. br.	Zavisna varijabla	Tip modela	R ²	MSE	RMSE	CVRMSE	MAPE
1	AEC	MLR	0,950	1,05E+07	3246,19	26,83%	27,70%
2	AEC	NN	0,959	8,68E+06	2946,77	24,35%	26,76%

Iz tablice se može vidjeti da i MLR i ANN modeli postižu visoke vrijednosti R² (0,950 za MLR i 0,959 za ANN), što ukazuje na snažnu pozitivnu korelaciju između predviđenih i stvarnih vrijednosti AEC. Međutim, MLR model ima viši MSE u usporedbi s ANN modelom. Iako je MSE teško izravno interpretirati zbog jedinica koje su kvadrati pogrešaka, niži MSE općenito sugerira bolje usklađivanje modela. Slično tome, MLR model ima nešto viši RMSE u usporedbi s ANN modelom. Slijedeći istu logiku, niži RMSE ukazuje na to da su predviđanja modela, u prosjeku, bliža stvarnim vrijednostima AEC. Oba modela imaju vrlo slične vrijednosti MAPE (oko 27%). S CVRMSE od 24,35 %, ANN model malo bolje generalizira neviđene podatke u usporedbi s MLR modelom (CVRMSE od 26,83 %). To sugerira da je ANN model manje sklon prekomjernom prilagođavanju na podatke za trening i može imati bolje performanse na novim podacima na kojima nije treniran. S obzirom na R² i CVRMSE, čini se da je ANN model bolji izbor

za predviđanje AEC. On postiže snažnu korelaciju sa stvarnim vrijednostima, a također malo bolje generalizira neviđene podatke. Nakon skupa podataka za trening, performanse razvijenih modela također su verificirane na skupu za validaciju, koji je neovisni skup na kojem razvoj modela nije proveden. Tablica 20 prikazuje vrijednosti prethodno spomenutih koeficijenata za procjenu pogreške predviđanja razvijenih MLR i ANN modela u skupu za validaciju modela.

Tablica 20 Točnosti razvijenih modela procjene potrošnje električne energije za skup podataka za validaciju

Red. br.	Zavisna varijabla	Tip modela	R^2	MSE	RMSE	CVRMSE	MAPE
1	AEC	MLR	0,949	1,25E+07	3537,51	20,50%	24,60%
2	AEC	NN	0,950	1,40E+07	3738,20	21,66%	27,46%

Oba modela postižu visoke vrijednosti R^2 (0,949 za MLR i 0,950 za ANN) na skupu podataka za validaciju, što ukazuje na snažnu pozitivnu korelaciju između predviđenih i stvarnih vrijednosti AEC. To sugerira da se oba modela generaliziraju prilično dobro na neviđenim podacima. MLR model ima malu prednost u pogledu MSE i RMSE u usporedbi s ANN. To sugerira da su predviđanja MLR modela, u prosjeku, nešto bliža stvarnim vrijednostima AEC u skupu za validaciju. Oba modela imaju dobre performanse na podacima za validaciju, s time da MLR model ima malu prednost u pogledu točnosti.

5.1.5. Zaključak

Zaključno, rezultati sugeriraju da su oba modela, MLR i ANN, učinkoviti alati za predviđanje potrošnje električne energije. Ovi rezultati su u skladu s postojećom literaturom i dodatno potvrđuju vrijednost primjene naprednih tehnika prediktivnog modeliranja za upravljanje energijom u školskim zgradama. Kao što je ranije spomenuto, ANN model, konfiguriran s MLP arhitekturom 3–5–1, postigao je R^2 vrijednosti od 0,959 i 0,950 za skupove treninga i validacije, što ukazuje na snažnu korelaciju između predviđenih i stvarnih vrijednosti. RMSE vrijednosti od 2946,77 za skup treninga i 3738,20 za skup validacije, zajedno s MAPE vrijednostima od 26,76 % i 27,46 %, sugeriraju da ANN model pruža točna predviđanja i učinkovito se generalizira na neviđene podatke. Ova izvedba modela usporediva je s rezultatima Gonzáleza i Zamarrénoa [231], koji su izvijestili o visokoj točnosti u procjeni električnog opterećenja koristeći povratnu ANN, te s radom Ahmada i sur. [104], koji su primijetili nešto bolju izvedbu ANN-a u odnosu na nasumične šume u predviđanju potrošnje energije HVAC sustava u hotelima.

Nadalje, kao što je ranije spomenuto, MLR model je postigao R^2 vrijednosti od 0,950 i 0,949 za skupove treninga i validacije, s RMSE vrijednostima od 3246,19 i 3537,51. MAPE vrijednosti od 27,70 % i 24,60 % u skladu su s izvedbom sličnih modela u literaturi. Na primjer, regresijski model Tso i Yaua [205], iako usporediv s modelima odluka i ANN, pokazao je male varijacije u izvedbi tijekom sezona. Slično tome, MLR model koji su predložili Run i sur. za predviđanje satne potrošnje električne energije u školskim zgradama postigao je niže R^2 vrijednosti od 74 % i 77 % za trening i validaciju [147].

Zaključno, modeli razvijeni za procjenu potrošnje električne energije pokazuju snažne metrike izvedbe, što ih čini pouzdanim alatima za predviđanje potrošnje električne energije u školskim zgradama.

5.2. Razvoj modela procjene potrošnje vode

5.2.1. Prikupljanje i analiza podataka za razvoj modela procjene potrošnje vode

Primjetan je nedostatak istraživanja o potrošnji vode u školskim zgradama, što se može vidjeti iz pregleda literature. Jasno je da postoji praznina koju treba popuniti daljnjim istraživanjem kako bi se bolje razumjelo korištenje vode u školskim zgradama i njime učinkovito upravljalo, što je ključno i za održivost i za učinkovito funkcioniranje zgrade.

Podaci korišteni za razvoj ovih modela uključuju podatke o potrošnji vode za 138 školskih zgrada u Osječko-baranjskoj županiji za razdoblje od 10 godina, od 2013. do 2023. godine. Podaci o potrošnji vode bilježe se na mjesečnoj razini, što omogućuje detaljnu analizu na mjesečnoj i godišnjoj razini.

Na početku razvoja modela bilo je važno utvrditi ulazne varijable koje utječu na potrošnju vode u školskim zgradama. Identifikacija ulaznih varijabli u procjeni potrošnje vode provedena je opsežnim pregledom prethodnih istraživanja. Tablica 21 prikazuje ulazne varijable koje su dostupne u ISGE skupu podataka u vezi s karakteristikama zgrade i koje su otkrivene kao značajne za predviđanje potrošnje vode u zgradama s istraživanjima u kojima su korištene.

Klimatski čimbenici poput temperature i oborina opće su poznati kao utjecajni faktori na potrošnju vode, posebno u područjima sa značajnim prostornim varijacijama klime. Međutim, Osječko-baranjska županija ima relativno ujednačenu kontinentalnu klimu s minimalnim varijacijama temperature i oborina unutar regije. Klima je obilježena umjerenim sezonskim promjenama, a nema značajnih mikroklimatskih uvjeta koji bi mogli uzrokovati primjetne razlike u obrascima potrošnje vode na području istraživanja.

Tablica 21 Identificirane značajne ulazne varijable za razvoj modela procjene potrošnje vode

Ulazne varijable	Oznaka	Mjerna jedinica	Izvor
Ukupan broj korisnika (djelatnika i učenika) (engl. <i>Total Number of Users</i>)	<i>TNU</i>	broj korisnika	[135, 232]
Korisna površina	A_k	m ²	[233-238]
Grijani volumen zgrade	V_e	m ³	[239]
Ukupan broj katova (engl. <i>Total Number of Floors</i>)	<i>TNF</i>	broj korisnika	[232, 240]
Starost zgrade (engl. <i>Age of Building</i>)	<i>AoB</i>	god	[232, 241, 242]

Nakon utvrđivanja ulaznih varijabli, bilo je potrebno utvrditi izlazne varijable koje su predstavljene u tablici 22.

Tablica 22 Izlazne varijable za razvoj modela procjene potrošnje vode

Izlazne varijable	Oznaka	Mjerna jedinica
Prosječna mjesečna potrošnja vode školske zgrade (engl. <i>Monthly Water Consumption</i>)	<i>MWC</i>	m ³ /mj
Prosječna godišnja potrošnja vode školske zgrade (engl. <i>Yearly Water Consumption</i>)	<i>YWC</i>	m ³ /god

Korištena je postupna regresija (engl. *stepwise regression*) za odabir najznačajnijih varijabli za razvoj modela. Varijable s p-vrijednošću manjom od 0,05 uključuju se u modele, dok se one s višom p-vrijednošću isključuju iz regresijske analize.

Stepwise postupci uključuju selekciju unaprijed (engl. *forward odnosno step-up*), eliminaciju unatrag (engl. *backward odnosno step-down*) i postupnu (engl. *stepwise*) regresiju. Ovi postupci funkcioniraju tako da postupno dodaju ili uklanjaju varijable jednu po jednu, sve dok nije ispunjeno određeno pravilo zaustavljanja. Metoda selekcije unaprijed započinje s praznim modelom, a zatim se u model dodaje varijabla koja ima najnižu p-vrijednost kada je uključena kao jedini prediktor. U svakom sljedećem koraku dodaje se varijabla s najnižom p-vrijednošću u odnosu na ostale prediktore koji su već u modelu. Varijable se dodaju jedna po jedna sve dok p-vrijednost ostaje dovoljno mala. Uobičajeno se smatra da je dovoljno mala vrijednost manja od 0,05 ili 0,10. Eliminacija unatrag započinje modelom koji uključuje sve prediktore. Zatim se iz modela uklanja varijabla s najvećom p-vrijednošću, nakon čega se model

ponovno prilagođava. U svakom sljedećem koraku uklanja se varijabla s najvećom p-vrijednošću sve dok ne ostane skup varijabli kod kojih je p-vrijednost manja od određene granice, koja je, kao što je prethodno navedeno, uobičajeno 0,05 ili 0,10. Postupna regresija je slična selekciji unaprijed, s tom razlikom što se varijable uklanjaju iz modela ako postanu nevažne nakon dodavanja drugih prediktora.

Prednost eliminacije unatrag je u tome što omogućuje identificiranje skupa varijabli koji ima značajnu prediktivnu moć, iako pojedinačne varijable možda nemaju. To je moguće jer metoda eliminacije unatrag započinje sa svim varijablama u modelu. Kod unaprijedne selekcije i stepwise regresije takve varijable možda neće biti prepoznate jer same po sebi ne predviđaju dobro te stoga ne ulaze u model, zbog čega njihovo zajedničko djelovanje može ostati neprimijećeno [243].

Varijable TNU, A_k i V_e pokazale su p-vrijednost manju od 0,05 u razvoju modela potrošnje vode na mjesečnoj i godišnjoj razini, što je prikazano u tablici 23, te su stoga odabrane za razvoj modela.

Tablica 23 Odabrane varijable korištenjem postupne metode regresije za razvoj modela procjene potrošnje vode

Nezavisna varijabla	Oznaka	p-vrijednost	
		Mjesečna potrošnja	Godišnja potrošnja
Ukupan broj korisnika	TNU	$1,5402 \cdot 10^{-23}$	$1,5794 \cdot 10^{-22}$
Korisna površina	A_k	$1,1852 \cdot 10^{-6}$	$1,7513 \cdot 10^{-5}$
Grijani volumen zgrade	V_e	$1,0661 \cdot 10^{-9}$	$4,8120 \cdot 10^{-15}$
Ukupan broj katova	TNF	0,193003	0,226433
Starost zgrade	AoB	0,434306	0,449293

Tablica 24 prikazuje deskriptivnu statistiku ulaznih i izlaznih varijabli modela procjene potrošnje vode.

Tablica 24 Deskriptivna statistika ulaznih i izlaznih varijabli modela procjene potrošnje vode

Vrsta varijable	Varijabla	Mjerna jedinica	N	Aritmetička sredina	Minimum	Maksimum	Standardna devijacija
Ulazna	TNU	broj	138	154,12	4,00	1114,00	200,92
	A_k	m ²	138	1127,25	37,70	5584,10	1261,83
	V_e	m ³	138	5006,06	113,10	25935,40	5878,52
Izlazna	MWC	m ³ /mj	138	22,60	0,45	118,96	25,36

	YWC	m ³ /god	138	259,29	5,25	1414,82	300,31
--	-----	---------------------	-----	--------	------	---------	--------


Ulazne varijable pokazuju značajnu varijabilnost, što je vidljivo iz njihovih standardnih devijacija i širokog raspona između minimalnih i maksimalnih vrijednosti.

- *TNU* ima aritmetičku sredinu od 154,12 sa standardnom devijacijom od 200,92, što ukazuje na značajnu varijaciju u broju korisnika unutar uzorka.
- *A_k* ima prosječnu vrijednost od 1127,25 sa standardnom devijacijom od 1261,83, što ukazuje na veliku varijabilnost u površini među zgradama. Minimalna vrijednost iznosi 37,7, dok maksimalna doseže 5584,1. Ovo sugerira da zgrade u uzorku značajno variraju u veličini, što bi moglo utjecati na potrošnju vode, budući da veće zgrade mogu imati veću potrošnju zbog više sadržaja i korisnika.
- *V_e* ima prosjek od 5006,06, sa standardnom devijacijom od 5878,52, što odražava veliku varijabilnost u veličinama zgrada. Volumen varira od 113,1 do 25935,4, što ukazuje na prisutnost i vrlo malih i vrlo velikih zgrada. Ova varijabilnost je važna jer volumen zgrade korelira s potražnjom za vodom – veće zgrade zahtijevaju više vode za aktivnosti poput grijanja, hlađenja i sanitacije.

Za izlazne varijable:


- *MWC* ima prosjek od 22,60 sa standardnom devijacijom od 25,36, što pokazuje umjerenu varijabilnost. Vrijednosti variraju od 0,45 do 118,96, što sugerira da većina zgrada troši umjerene količine vode, dok neke pokazuju neuobičajeno nisku ili visoku potrošnju, što bi moglo biti rezultat neučinkovitosti ili specifičnih potreba zgrada (primjerice, škole s programima kuhanja).
- *YWC* ima prosjek od 259,26 i standardnu devijaciju od 300,34. Raspon od 5,25 do 1414,82 naglašava da neke zgrade možda koriste vodu pretjerano, dok druge imaju vrlo nisku potrošnju, što potencijalno ukazuje na razlike u obrascima korištenja zgrada, tehnologijama za uštedu vode ili ponašanju korisnika.

Slika 5 prikazuje histogram varijable *MWC* i asimetričnu distribuciju mjesečne potrošnje vode, budući da više od 50 % promatranih vrijednosti mjesečne potrošnje vode pripada u raspon od 0 do 20 m³/mjesečno.




Slika 5 Histogram mjesečne potrošnje vode

Izrađen je i histogram za distribuciju mjesečne potrošnje vode po korisniku ($\text{m}^3/\text{mj}/\text{korisnik}$) (Slika 6). Kao što se vidi na histogramu, većina škola ima relativno nisku potrošnju vode, posebno u rasponu od 0 do $0,2 \text{ m}^3/\text{mj}/\text{korisnik}$. Velika učestalost na vrijednosti od $0,1 \text{ m}^3/\text{mj}/\text{korisnik}$ ukazuje da mnoge škole iz uzorka troše približno ovu količinu vode mjesečno po korisniku. To bi moglo biti povezano s brojem učenika, osoblja i sadržaja u svakoj zgradi, kao i s praksama očuvanja vode.




Slika 6 Histogram mjesečne potrošnje vode po korisniku

Slika 7 prikazuje histogram varijable YWC te je iz nje vidljiva asimetrična distribucija godišnje potrošnje vode, budući da više od 50 % promatranih vrijednosti godišnje potrošnje vode pripada u raspon od 0 do 200 m³/godina.



Slika 7 Histogram godišnje potrošnje vode

Kao i u slučaju mjesečne potrošnje, izrađen je histogram godišnje potrošnje po korisniku (Slika 8) i pokazuje da je, slično prethodnom histogramu, većina opažanja pripada nižem rasponu, osobito oko 0 do 2 m³/godina/korisnik. Više od 70 zgrada prikazuje potrošnju vode ispod 2 m³/godina/korisnik, što ukazuje na to da većina škola održava nisku godišnju potrošnju vode po korisniku.



Slika 8 Histogram godišnje potrošnje vode po korisniku

Budući da skup podataka uključuje i male područne škole, to je doprinijelo prevladavanju nižih vrijednosti potrošnje vode. Male područne škole obično imaju manji broj učenika i djelatnika u usporedbi s većim, što rezultira nižom potrošnjom vode zbog manje zahtjevnosti sanitarnih sadržaja, rada kantine i održavanja okoliša.

Razvijena su četiri modela za predviđanje potrošnje vode u školskim zgradama: dva modela temelje se na prosječnoj mjesečnoj potrošnji školske zgrade (m^3/mjesec), jedan razvijen korištenjem višestruke linearne regresije i jedan korištenjem umjetne neuronske mreže, dok se druga dva modela temelje na godišnjoj prosječnoj potrošnji vode školske zgrade (m^3/godina), također s jednim modelom razvijenim korištenjem višestruke linearne regresije i jednim korištenjem umjetne neuronske mreže

Odabir mjesečnih i godišnjih vremenskih koraka temelji se na njihovoj izravnoj primjenjivosti u praktičnom upravljanju vodnim resursima i dugoročnom strateškom donošenju odluka. Ovi vremenski koraci su odabrani kako bi pružili uvid u dvije različite perspektive: mjesečni korak za praćenje kratkoročnih oscilacija, a godišnji za razumijevanje dugoročnih trendova potrošnje.

Početni skup podataka podijeljen je u dva skupa nasumično – skup za treniranje, koji je korišten za izradu ili razvoj modela, i skup za validaciju, koji je korišten isključivo za procjenu pogrešaka razvijenih modela. U skupu za trening nasumično je odabrano 98 školskih zgrada, što čini 71,01 % od ukupno 138 školskih zgrada, a u skupu za validaciju nalazi se 40 školskih zgrada ili 28,99 % od ukupnog broja.

5.2.2. Razvijeni modeli procjene potrošnje vode pomoću višestruke linearne regresije

U razvoju modela mjesečnog predviđanja korišteni su podaci o prosječnoj mjesečnoj potrošnji vode za 98 škola, a utvrđeno je da najbolji razvijeni model višestruke linearne regresije za zavisnu varijablu MWC , koji predviđa prosječnu mjesečnu potrošnju vode školske zgrade, ima sljedeći oblik:

$$MWC = 1,322 + 0,084\ TNU + 0,0036\ A_k + 0,001\ V_e\ [m^3/mj] \quad (3)$$

Najbolji razvijeni model pomoću višestruke linearne regresije za zavisnu varijablu YWC , koji predviđa prosječnu godišnju potrošnju vode školske zgrade, ima sljedeći oblik:


$$YWC = 5,132 + 0,814\ TNU + 0,050\ A_k + 0,014\ V_e\ [m^3/god] \quad (4)$$

gdje je:

- TNU : Nezavisna varijabla koja predstavlja ukupan broj korisnika, uključujući djelatnike i učenike (broj),
- A_k : Nezavisna varijabla koja predstavlja ukupnu korisnu površinu zgrade (m^2),
- V_e : Nezavisna varijabla koja predstavlja obujam zgrade (m^3).


5.2.3. Razvijeni modeli procjene potrošnje vode pomoću umjetnih neuronskih mreža

Za razvoj modela korišten je višeslojni perceptron tip umjetne neuronske mreže. Slika 9 prikazuje arhitekturu optimalno odabranog modela procjene mjesečne potrošnje vode.



Slika 9 Optimalni odabrani model procjene mjesečne potrošnje vode (MLP 3-4-1)

Slika 10 prikazuje arhitekturu optimalno odabranog modela procjene godišnje potrošnje vode.



Slika 10 Optimalni odabrani model procjene godišnje potrošnje vode (MLP 3-3-1)

5.2.4. Usporedba točnosti razvijenih modela procjene potrošnje vode

Točnosti razvijenih modela ocijenjene su pomoću izraza korištenih za izračun statističkih tehnika za procjenu pogreške predviđanja prethodno prikazanih u tablici 18.


Tablica 25 prikazuje točnosti razvijenih modela procjene mjesečne i godišnje potrošnje vode za skup podataka za trening.

Tablica 25 Točnosti razvijenih modela procjene mjesečne i godišnje potrošnje vode za skup podataka za trening

R. br.	Vrsta modela	Zavisna varijabla	R^2	MSE	RMSE	CVRMSE	MAPE
1	MLR	YWC	0,957	3993,92	63,20	24,98 %	27,41%
2	ANN	YWC	0,960	3676,68	60,64	23,97 %	30,66 %
3	MLR	MWC	0,974	17,37	4,17	18,93 %	22,61%
4	ANN	MWC	0,974	17,37	4,17	18,93 %	22,61 %

Oba modela pokazuju visoke vrijednosti R^2 , što ukazuje na snažnu korelaciju između predviđenih i stvarnih vrijednosti potrošnje vode. Za YWC , umjetna neuronska mreža (0,960) malo nadmašuje

višestruka linearnu regresiju (0,957), a za MWC, umjetna neuronska mreža postiže istu vrijednost kao i regresija (0,974 i 0,974). Ove visoke vrijednosti R^2 sugeriraju da su oba modela učinkovita u objašnjavanju varijance u potrošnji vode školskih zgrada. Umjetna neuronska mreža općenito proizvodi niže MSE i RMSE za godišnju potrošnju, dok postiže iste vrijednosti za mjesečnu potrošnju kao i regresija. Na primjer, MSE za umjetnu neuronsku mrežu (3676,68) je niži od MSE za višestruka linearnu regresiju (3993,92) za YWC, što pokazuje bolju točnost predviđanja za umjetnu neuronsku mrežu u godišnjoj potrošnji. Umjetna neuronska mreža pokazuje nešto niži CVRMSE za YWC (23,97 %), a isti za MWC (17,52%), što znači da predviđanja umjetne neuronske mreže imaju kod godišnje potrošnje nešto manju relativnu varijabilnost u usporedbi s višestrukom linearnom regresijom. To sugerira da je umjetna neuronska mreža stabilnija između različitih škola, s manjom varijacijom u pogrešci predviđanja u odnosu na prosječnu potrošnju. Za YWC, višestruka linearna regresija ima bolje rezultate ako se promatra MAPE od 27,41 %, u usporedbi s neuronskom mrežom koja ima 30,66 %. To znači da višestruka linearna regresija daje točnija predviđanja u postotnim vrijednostima za godišnju potrošnju vode, kao što je navedeno u literaturi [117]. Dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje vode u skupu podataka za trening prikazani su u slici 11.




Slika 11 Dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje vode u skupu podataka za trening


Tablica 26 prikazuje točnosti razvijenih modela procjene mjesečne i godišnje potrošnje vode za skup podataka za validaciju.

Tablica 26 Točnosti razvijenih modela procjene mjesečne i godišnje potrošnje vode za skup podataka za validaciju

R. br.	Vrsta modela	Zavisna varijabla	R^2	MSE	RMSE	CVRMSE	MAPE
1	MLR	YWC	0,900	6763,47	82,24	29,94 %	27,44 %
2	ANN	YWC	0,920	6564,76	81,02	29,49 %	27,57 %
3	MLR	MWC	0,945	27,46	5,24	23,00 %	24,21 %
4	ANN	MWC	0,947	26,16	5,11	22,45 %	21,49 %

Za skup podataka za validaciju, oba modela pokazuju snažnu predikciju, pri čemu umjetna neuronska mreža općenito nadmašuje višestruku linearnu regresiju u većini metrika. Umjetna neuronska mreža postiže više vrijednosti R^2 za obje zavisne varijable: za YWC (0,920 u odnosu na 0,900) te za MWC (0,947 u odnosu na 0,945). Modeli umjetne neuronske mreže također pokazuju niže vrijednosti MSE i RMSE, što pokazuje bolju točnost u objašnjavanju varijance u potrošnji vode. Na primjer, MSE za YWC s umjetnom neuronskom mrežom iznosi 6564,76, u usporedbi s 6763,47 za višestruku linearnu regresiju, dok je za MWC RMSE 5,11 za umjetnu neuronsku mrežu, a 5,24 za višestruku linearnu regresiju. CVRMSE vrijednosti su relativno usporedive između modela, ali umjetna neuronska mreža postiže nešto bolje MAPE vrijednosti za MWC (21,49 % u odnosu na 24,21 %). Ovi rezultati potvrđuju rezultate iz skupa podataka za trening, ukazujući na to da umjetna neuronska mreža ima malu prednost u odnosu na višestruku linearnu regresiju zbog svoje sposobnosti učinkovitijeg modeliranja nelinearnih odnosa. Dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje vode u skupu podataka za validaciju prikazani su u slici 12.





Slika 12 Dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje vode u skupu podataka za validaciju

5.2.5. Zaključak

Rezultati pokazuju da su oba modela, MLR i ANN, učinkovita u predviđanju potrošnje vode, s visokim R^2 vrijednostima koje ukazuju na jake korelacije između predviđene i stvarne potrošnje. Međutim, modeli pokazuju različite prednosti: MLR bolje funkcionira u kontekstu MAPE vrijednosti za predviđanje godišnje potrošnje vode (YWC) u skupu podataka za trening, što sugerira da pruža interpretabilniju i točniju pogrešku u postotku za godišnje prognoze. S druge strane, ANN pokazuje superiornost u većini drugih metrika, kao što su MSE, RMSE i CVRMSE, osobito u skupu podataka za validaciju, s boljim R^2 za YWC i nižim vrijednostima pogreške od MLR-a što ukazuje na sposobnost ANN-a da modelira složene, nelinearne odnose u potrošnji vode. Zanimljivo je da se razlika u izvedbi između modela smanjuje za skup podataka za validaciju, što naglašava robusnost obje metode. Rezultati sugeriraju da, dok je MLR prikladan za bilježenje linearnih odnosa i nudi bolju interpretabilnost, ANN se ističe u prepoznavanju nelinearnih interakcija, što bi moglo biti ključno za dugoročne strategije upravljanja vodama.

Rezultati također ukazuju na važnost primjene oba modela u različitim scenarijima, ovisno o specifičnim ciljevima analize i korisnicima. Iako ANN model nudi veću preciznost u predviđanjima i bolje se nosi sa složenim, nelinearnim odnosima, njegova interpretabilnost može biti izazov za korisnike koji nemaju tehničko ili specijalizirano znanje u strojnom učenju. S obzirom na to, MLR model nudi prednost u kontekstu jednostavnijeg razumijevanja i primjene, što je od velike važnosti za praktičnu upotrebu u svakodnevnom upravljanju resursima. Naime, MLR omogućava korisnicima da lakše razumiju koji faktori najviše utječu na potrošnju vode, čineći ga korisnijim alatom za ravnatelje škola, domare i druge korisnike koji nisu stručnjaci u analizi podataka. S obzirom na specifičnosti obrazovnih objekata, gdje je lako razumjeti ključne varijable koje utječu na potrošnju, MLR može biti prvi izbor u situacijama gdje je

interpretabilnost najvažnija, dok bi ANN mogao biti koristan u kontekstu gdje su potrebna detaljnija predviđanja u složenijim uvjetima.

5.3. Razvoj modela procjene potrošnje toplinske energije

5.3.1. Prikupljanje i analiza podataka za razvoj modela procjene potrošnje toplinske energije

Podaci korišteni za razvoj modela potrošnje toplinske energije uključuju podatke o potrošnji toplinske energije za 149 školskih zgrada u Osječko-baranjskoj županiji za razdoblje od 10 godina, od 2013. do 2023. godine. Na početku razvoja modela bilo je važno utvrditi ulazne varijable koje utječu na potrošnju toplinske energije u školskim zgradama. Identifikacija najkritičnijih ulaznih čimbenika u analizi potrošnje vode provedena je opsežnim pregledom prethodnih istraživanja. Tablica 27 prikazuje ulazne varijable koje su dostupne u ISGE skupu podataka u vezi s karakteristikama zgrade i koje su otkrivene kao značajne za predviđanje potrošnje toplinske energije u zgradama. Također, uključena su relevantna istraživanja u kojima su korištene ove varijable.

Tablica 27 Identificirane značajne ulazne varijable za razvoj modela procjene potrošnje toplinske energije

Ulazne varijable	Oznaka	Mjerna jedinica	Izvor
Ukupan broj korisnika (djelatnika i učenika) (engl. <i>Total Number of Users</i>)	TNU	broj korisnika	[139, 244-246]
Korisna površina	A_k	m ²	[139, 206, 247, 248]
Grijani volumen zgrade	V_e	m ³	[139, 247, 249]
Ukupan broj katova (engl. <i>Total Number of Floors</i>)	TNF	broj korisnika	[139, 250]
Starost zgrade (engl. <i>Age of Building</i>)	AoB	god	[206, 251-253]
Starost od zadnje obnove (engl. <i>Age of Renovation</i>)	AoR	god	[251, 254, 255]
Udio ploštine prozora u ukupnoj ploštini pročelja (engl. <i>Window-to-wall ratio</i>)	WWR	%	[99, 250, 256-258]
Faktor oblika (engl. <i>Form Factor</i>)	f_o	m ⁻¹	[250, 259, 260]

Koeficijent transmisijskog toplinskog gubitka (engl. <i>Heat Transfer Coefficient</i>)	H_T	W/K	[139, 261, 262]
--	-------	-----	-----------------

Također, nakon određivanja ulaznih varijabli, bilo je potrebno odrediti izlaznu (zavisnu) varijablu, koja je prikazana u tablici 28.

Tablica 28 Izlazna varijabla za razvoj modela procjene potrošnje toplinske energije

Izlazna varijabla	Oznaka	Mjerna jedinica
Prosječna godišnja potrošnja toplinske energije (engl. <i>Annual Heating Energy Consumption</i>)	<i>AHC</i>	kWh/god

Za analizu prikladnosti ulaznih varijabli korištena je analiza statističke značajnosti (p-vrijednosti) te korelacijskog koeficijenta s izlaznom varijablom. Kao što je već ranije navedeno statistički značajnim varijablama se smatraju one koje su pokazale p vrijednost manju od 0,05. Osim toga, nakon analize statističke značajnosti analizirana je i korelacija ulaznih varijabli s izlaznom. U ovom kontekstu važno je spomenuti vrijednosti koeficijenta korelacije odnosno opis povezanosti koji on predstavlja (Tablica 29) [263].

Tablica 29 Vrijednosti koeficijena korelacije i opis povezanosti [263]

r	Opis povezanosti
-1	Potpuna negativna korelacija
od -0,7 do -1	Snažna negativna korelacija
od -0,3 do -0,7	Umjerena negativna korelacija
od -0,3 do +0,3	Slaba korelacija
0	Nema korelacije
od +0,3 do +0,7	Umjerena pozitivna korelacija
od +0,7 do +1	Snažna pozitivna korelacija
+1	Potpuna pozitivna korelacija

U tablici 30 prikazane su korelacije ulaznih varijabli s izlaznom s time da su **crveno** označene varijable koje su pokazale p-vrijednost manju od 0,05.

Tablica 30 Korelacije ulaznih varijabli s izlaznom varijablom *AHC*

Varijabla	Korelacija s izlaznom varijablom <i>AHC</i>
<i>TNU</i>	0,7839
A_k	0,8513
V_e	0,8830
<i>TNF</i>	0,6052
<i>AoB</i>	-0,0042
<i>AoR</i>	-0,1245
<i>WWR</i>	0,3214
f_o	-0,3256
H_T	0,3134

S obzirom na ranije navedene vrijednosti koeficijenata korelacije vidljivo je da su samo tri (*TNU*, A_k , i V_e) ulazne varijable pokazale snažnu korelaciju s izlaznom varijablom te su iz toga razloga dalje i razmatrane za razvoj modela.

Tablica 31 prikazuje deskriptivnu statistiku ulaznih i izlaznih varijabli modela procjene potrošnje toplinske energije.

Tablica 31 Deskriptivna statistika ulaznih i izlaznih varijabli modela procjene potrošnje toplinske energije

Vrsta varijable	Varijabla	Mjerna jedinica	N	Aritmetička sredina	Minimum	Maksimum	Standardna devijacija
Ulazna	<i>TNU</i>	broj	149	145,30	3,00	730,00	182,4
	A_k	m ²	149	1183,60	60,00	6210,3	1324,9
	V_e	m ³	149	4703,00	116,00	21185,1	5217,1
Izlazna	<i>AHC</i>	kWh/god	149	121612,82	8070,21	508983,2	126492,7

Analiza deskriptivne statistike pokazuje značajne varijacije u svim analiziranim varijablama, što odražava različite tipove i veličine objekata. Prosječan broj korisnika iznosi 145,3, a raspon broja korisnika kreće se od 3 do 730, što sugerira da u analizi postoje škole različitih veličina, od malih područnih do većih škola s velikim brojem učenika. Korisna površina škola u prosjeku iznosi 1183,6 m², a varira od 60 m² do 6210,3 m², što ukazuje na široki raspon veličina objekata, od malih škola do velikih zgrada s brojnim

učionicama i sadržajima. Slično tome, prosječan volumen škola je 4703 m³, a raspon volumena je između 116 m³ i 21185 m³, što također potvrđuje varijacije u veličini i prostoru među školama. Godišnja potrošnja toplinske energije u prosjeku iznosi 121612,82 kWh/god, ali varira od 8070,21 kWh/god do 508983,2 kWh/god, što odražava velike razlike u energetskej učinkovitosti među školama.

Početni skup podataka podijeljen je u dva skupa nasumično – skup za treniranje (engl. *training set*), koji je korišten za izradu ili razvoj modela, i skup za validaciju (engl. *validation set*), koji je korišten isključivo za procjenu pogrešaka razvijenih modela. U skupu za trening nasumično je odabrano 105 školskih zgrada, što čini 70,5 % od ukupno 149 školskih zgrada, a u skupu za validaciju nalazi se 44 školske zgrade ili 29,5 % od ukupnog broja. Slični omjeri korišteni su i u [211, 212].

5.3.2. Razvijeni model procjene potrošnje toplinske energije pomoću višestruke linearne regresije

U razvoju modela procjene godišnje potrošnje toplinske energije korišteni su podaci o prosječnoj godišnjoj potrošnji toplinske energije za 105 škola, a utvrđeno je da najbolji razvijeni model višestruke linearne regresije za zavisnu varijablu AHC , koja predstavlja godišnju potrošnju toplinske energije zgrade, ima sljedeći oblik:


$$AHC = 6140,533 + 146,11 TNU + 24,999 A_k + 13,484 V_e \text{ [kWh/god]} \quad (5)$$

gdje je:

- TNU : Nezavisna varijabla koja predstavlja ukupan broj korisnika, uključujući djelatnike i učenike (broj),
- A_k : Nezavisna varijabla koja predstavlja ukupnu korisnu površinu zgrade (m²),
- V_e : Nezavisna varijabla koja predstavlja obujam zgrade (m³).

5.3.3. Razvijeni model procjene godišnje potrošnje toplinske energije pomoću umjetne neuronske mreže

Za razvoj modela korišten je višeslojni perceptron MLP tip umjetne neuronske mreže. Slika 13 prikazuje arhitekturu optimalno odabranog modela procjene godišnje potrošnje toplinske energije.



Slika 13 Optimalni odabrani model procjene godišnje potrošnje toplinske energije (MLP 3-6-1)

5.3.4. Razvijeni model procjene godišnje potrošnje toplinske energije pomoću algoritma nasumične šume

Nasumične šume su veći skup ili skupina odlučujućih stabala [264]. Naziv algoritma dolazi od tehnike strojnog učenja koju algoritam koristi. Algoritam stvara veliki broj odlučujućih stabala iz dostupnih podataka za učenje – šumu slučajnih stabala. Prilikom izgradnje svakog stabla u šumi, algoritam slučajnim odabirom odabire podskup podataka i podskup ulaznih varijabli skupa [265, 266]. RF ima

mnoge zanimljive značajke, poput precizne moći predviđanja (koja je usporediva s ili čak nadmašuje umjetne neuronske mreže i algoritme potpornih vektora), malu sklonost pretreniranju modela, ne zahtijeva veliku računalnu snagu i dobro se nosi s podacima velikih dimenzija [267]. Jedna od glavnih prednosti algoritma je otpornost na pretreniranost, jer rastući broj slučajnih odlučujućih stabala ne stvara rizik od pretreniranja modela (svako stablo je potpuno neovisni slučajni eksperiment). Algoritam je također robustan prema iznimkama u podacima i automatski se nosi s nedostajućim vrijednostima [268]. U literaturi je navedeno da je najveći dobitak u izvedbi postignut kada se trenira prvih 100 stabala [269]. Tablica 32 prikazuje važnosti prediktora ulaznih varijabli. Ove vrijednosti obično su normalizirane tako da najvažnija varijabla ima važnost 1.

Tablica 32 Važnosti prediktora ulaznih varijabli modela procjene potrošnje toplinske energije

Varijabla	Rang varijable	Važnost
V_e	100	1,000000
TNU	98	0,984450
A_k	89	0,894564

5.3.5. Usporedba točnosti razvijenih modela procjene potrošnje toplinske energije


Točnosti razvijenih modela ocijenjene su pomoću izraza korištenih za izračun statističkih tehnika za procjenu pogreške predviđanja prethodno prikazanih u tablici 18. Tablica 33 prikazuje točnosti razvijenih modela procjene potrošnje toplinske energije za skup podataka za trening.

Tablica 33 Točnosti razvijenih modela procjene potrošnje toplinske energije za skup podataka za trening

R. br.	Vrsta modela	Zavisna varijabla	R^2	MSE	RMSE	CVRMSE	MAPE
1	MLR	AHC	0,913	1,31E+09	36803,43	29,65 %	35,67 %
2	ANN		0,943	9,07E+08	30110,14	24,26 %	27,51 %
3	RF		0,872	1,64E+09	40517,16	32,64 %	28,87 %

Model umjetne neuronske mreže (ANN) pokazao se najuspješnijim s najvišim koeficijentom determinacije ($R^2 = 0,943$), što znači da objašnjava najveći dio varijabilnosti zavisne varijable. Uz to, ANN ima najniže vrijednosti MSE (9,07E+08) i RMSE (30110,14), što ukazuje na najveću točnost predikcije u

usporedbi s ostalim modelima. S druge strane, višestruka linearna regresija (MLR) ima solidan rezultat s $R^2 = 0,913$, ali se ističe kao model s najvišom relativnom pogreškom MAPE (35,67%), što ukazuje na manje precizne procjene u usporedbi s ANN i RF. Model slučajnih šuma (RF) ima najniži koeficijent determinacije ($R^2 = 0,872$) te najviše apsolutne pogreške (MSE = 1,64E+09, RMSE = 40517,16), no njegova relativna pogreška MAPE (28,87%) je manja od one kod MLR-a. Dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje toplinske energije u skupu podataka za trening prikazani su u slici 14.




Slika 14 Dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje toplinske energije u skupu podataka za trening


Tablica 34 prikazuje točnosti razvijenih modela procjene potrošnje toplinske energije za skup podataka za validaciju.

Tablica 34 Točnosti razvijenih modela procjene potrošnje toplinske energije za skup podataka za validaciju

R. br.	Vrsta modela	Zavisna varijabla	R^2	MSE	RMSE	CVRMSE	MAPE
1	MLR	AHC	0,897	1,34E+09	36574,16	31,63 %	39,93 %
2	ANN		0,888	1,39E+09	37307,65	32,27 %	36,54 %
3	RF		0,732	2,23E+09	47207,78	40,83 %	34,65 %

Iz tablice rezultata za validaciju, mogu se primijetiti promjene u performansama modela u odnosu na rezultate za trening. MLR i dalje pokazuje relativno visoke performanse, s $R^2 = 0,897$, što znači da objašnjava 89,7% varijance u podacima. Također, MSE (1,34E+09) i RMSE (36574,16) ostaju slični onima iz trening skupa, dok je MAPE (39,93 %) veći nego u trening skupu, što ukazuje na nešto veću pogrešku u predviđanjima za validacijski skup. ANN također ima smanjene performanse u odnosu na trening, s $R^2 = 0,888$ i MSE = 1,39E+09, što ukazuje na veću pogrešku u predviđanjima nego što ih je bilo tijekom treniranja. RF model bilježi najveći pad u performansama, s $R^2 = 0,732$, što znači da model objašnjava samo 73,2 % varijance u validacijskim podacima, što je značajno niže od onog što je postignuto u trening fazi. Osim toga, MSE = 2,23E+09 i RMSE = 47207,78 ukazuju na veće pogreške u predviđanjima, a MAPE = 34,65 % je bolji nego kod MLR-a i ANN-a. Na slici 15 prikazani su dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje toplinske energije u skupu podataka za validaciju.





Slika 15 Dijagrami rasipanja procijenjenih i stvarnih vrijednosti potrošnje toplinske energije u skupu podataka za validaciju

S obzirom na jednostavnost primjenjivosti među upraviteljima školskih zgrada i ravnateljima, MLR je najprikladniji model. Iako nije najprecizniji, s $R^2 = 0,897$ na validaciji, MLR je jednostavan za implementaciju i razumijevanje, što omogućava lakšu interpretaciju njegovih rezultata. Ovaj model ne zahtijeva napredne računalne resurse i lako je primjenjiv u svakodnevnoj administraciji, jer pruža jasne uvide u to koji faktori utječu na potrošnju toplinske energije. S druge strane, ANN nudi bolju preciznost u treningu ($R^2 = 0,943$), ali je složeniji za implementaciju i razumijevanje. Za korisnike koji nisu stručnjaci u analizi podataka, ANN može biti izazovan zbog svoje prirode "crne kutije" i potrebe za većim računalnim resursima. RF je također vrlo precizan, no zbog visoke složenosti i računalnih zahtjeva može biti težak za primjenu u školama koje nemaju odgovarajuću infrastrukturu. Također, RF je pretrpio najveći pad u preciznosti na validacijskom skupu, što dodatno naglašava njegovu osjetljivost na varijacije u podacima. U konačnici, za većinu škola koje traže praktičnost i jednostavnost, MLR je najpogodniji model, dok ANN i RF mogu biti korisni u specifičnim uvjetima s većim resursima.

5.3.6. Zaključak

Usporedba točnosti razvijenih modela za procjenu potrošnje toplinske energije pokazuje značajne razlike u izvedbi između MLR, ANN i RF modela. Iako je RF model ostvario zadovoljavajuće rezultate u trening skupu, njegov pad performansi na validacijskom skupu (s R^2 od 0,732) ukazuje na njegovu

sklonost „overfittingu“. To znači da, iako RF dobro funkcionira na podacima na kojima je treniran, njegovu sposobnost generalizacije na neviđene podatke ometa veća osjetljivost na varijacije u podacima. S druge strane, ANN model je pokazao vrlo dobre rezultate, s R^2 od 0,943 na treningu, no također s padom performansi na validaciji ($R^2 = 0,888$). Iako je ANN precizniji od MLR-a u većini mjerenja, njegova složenost i potreba za većim računalnim resursima mogu predstavljati prepreku za korisnike bez tehničkog znanja. MLR model, iako nije najprecizniji, s R^2 od 0,897 na validaciji i relativno većim MAPE vrijednostima (39,93%), pokazuje stabilne performanse i veću interpretabilnost. Zbog svoje jednostavnosti i lakše implementacije, MLR je najsvrsishodniji model za praktičnu primjenu u školama, osobito u uvjetima kada se traže rješenja koja su jednostavna za razumijevanje i primjenu bez potrebe za naprednim tehničkim resursima.

5.4. Usporedba stvarne i proračunske potrošnje toplinske energije

5.4.1. Prikupljanje i analiza podataka za usporedbu stvarne i proračunske potrošnje toplinske energije

U Republici Hrvatskoj, prema izračunu specifične godišnje potrebne toplinske energije za grijanje $Q_{H,nd,ref}$ zgrada se klasificira u energetske razrede, pri čemu je A+ razred s najmanjom potrošnjom toplinske energije za grijanje ($Q''_{H,nd} \leq 15 \text{ kWh}/(\text{m}^2\text{a})$), dok je G razred onaj s najvećom potrošnjom energije ($Q''_{H,nd} > 250 \text{ kWh}/(\text{m}^2\text{a})$) (Tablica 35) [270].

Tablica 35 Energetski razredi zgrada [270]

Energetski razred	$Q''_{H,nd}$ – specifična godišnja potrebna toplinska energija za grijanje [$\text{kWh}/(\text{m}^2\text{a})$]
A+	≤ 15
A	≤ 25
B	≤ 50
C	≤ 100
D	≤ 150
E	≤ 200
F	≤ 250

G	> 250
---	-------

Od 2017. godine zgrade se također svrstavaju u još jedan energetske razred na temelju izračuna specifične godišnje primarne energije za referentne klimatske podatke i Algoritmom propisan režim rada tehničkih sustava [271]. Međutim, budući da su mnogi energetske certifikati analizirani u ovom istraživanju stariji od 2017. godine, ovaj razred nije uzet u obzir te se analiza provodi samo za toplinsku energiju potrebnu za grijanje. Većina škola ušla je u proces izrade energetskog certifikata školske zgrade 2011. godine kada je postao obavezan.

Godišnja potreba za energijom izražava se s pomoću stupanj dana, što predstavlja umnožak broja dana grijanja i temperaturne razlike između zadane unutarnje temperature (20 °C) i vanjske temperature. U izračun se uzimaju samo oni dani u godini kada je vanjska temperatura niža od 12 °C. Osječko-baranjska županija po svom položaju pripada kontinentalnom dijelu Hrvatske. Kontinentalna Hrvatska su gradovi i mjesta koja imaju 2200 i više stupnjeva dana grijanja, a godišnje potrebe za energijom izračunavaju se prema referentnim klimatskim podacima za kontinentalnu Hrvatsku. Za izračun broja stupanj dana uzima se srednja vanjska temperatura svih dana grijanja u sezoni i oduzme se od dogovorene unutrašnje temperature 20 °C te se pomnoži s ukupnim brojem dana grijanja. Konkretno, vrijednost stupanj dana za grad Osijek iznosi 2676 [270].

Energetski certifikati prikupljeni su za 81 osnovnu i 13 srednjih škola u Osječko-baranjskoj županiji te je iz njih preuzeta proračunska potrošnja energije za školske zgrade. Stvarne potrošnje toplinske energije za grijanje za iste školske zgrade za koje su prikupljeni energetske certifikati, preuzete su iz ranije navedenog ISGE sustava.

Analiza podataka iz energetskih certifikata i stvarnih podataka provedena je koristeći TIBCO Statistica® 14.1.0 [202] i Microsoft Excel radne knjige [201] kompatibilne s navedenim softverom. Kako bi se osigurala usporedivost između podataka iz energetskih certifikata i stvarnih podataka, prikupljeni su podaci o stvarnoj potrošnji toplinske energije za grijanje za 94 školske zgrade u razdoblju od 2018. do 2022. na godišnjoj razini. Ti podaci su zatim podijeljeni s korisnom površinom školskih zgrada kako bi se dobila ista mjerna jedinica za $Q''_{H,nd}$ – specifična godišnja potrebna toplinska energija za grijanje [kWh/(m²a)] kao u energetskim certifikatima.

Tablica 36 prikazuje analizu deskriptivne statistike za podatke iz energetskih certifikata i stvarne podatke, gdje se vidi da su prosječne i medijan vrijednosti stvarne potrošnje značajno više od onih u energetskim certifikatima. To sugerira da stvarna potrošnja energije, u prosjeku, premašuje očekivane


vrijednosti. Međutim, minimalna potrošnja energije prema energetske certifikatima je viša od stvarne potrošnje, što je vrlo vjerojatno uzrokovano netočnim mjerenjima ili krivim unosima korisnika.

Tablica 36 Analiza deskriptivne statistike energetske certifikata i stvarne potrošnje toplinske energije za grijanje

Varijabla	N	Aritmetička sredina	Medijan	Min.	Max.	Donji kvartil	Gornji kvartil
Proračunska $Q''_{H,nd}$ [kWh/(m ² a)]	94	82,06	67,13	17,00	238,00	39,00	116,06
Stvarna $Q''_{H,nd}$ [kWh/(m ² a)]	94	105,52	102,02	0,46	239,79	75,36	136,70

Također, donji i gornji kvartil za stvarnu potrošnju energije znatno su viši od proračunskih vrijednosti, što ukazuje na značajan dio slučajeva u kojima stvarna potrošnja prelazi gornji očekivani prag. Općenito, ova analiza sugerira da bi se trebala analizirati značajna odstupanja između proračunskih i stvarnih energetske performansi.

Slika 16 prikazuje analizu ukupnog broja svakog energetske razreda u skupu podataka i za proračunske i za stvarne podatke. Energetski razredi za stvarne podatke utvrđeni su na temelju tablice 35, koja kategorizira zgrade prema specifičnoj godišnjoj potrebnoj toplinskoj energiji za grijanje. Iz statistike stvarne potrošnje vidljivo je da su tri zgrade svrstane u energetski razred A+. Međutim, prema energetske certifikatima, nijedna zgrada ne pripada ovoj kategoriji. To je vjerojatno rezultat pogrešnih mjerenja potrošnje, što dovodi do preniskih vrijednosti potrošnje, kao što je gore navedena nerealna minimalna vrijednost stvarne potrošnje. Detaljna analiza potrošnje ovih zgrada pokazala je da, iako je promatrana prosječna godišnja potrošnja, nema značajnijih odstupanja individualne potrošnje po godinama. Ovime se naglašava važnost određivanja energetske jaza i sugerira da su ili stvarne potrošnje netočno zabilježene ili postoji netočnost energetske certifikata.



Slika 16 Zastupljenost energetske razreda u uzorku prema proračunskoj i prema stvarnoj potrošnji

Nadalje, može se vidjeti da je većina zgrada ocijenjena u srednjim kategorijama energetske razreda (B, C i D). Što se tiče stvarne potrošnje, najveći broj zgrada pripada u C i D razrede. Osim nepostojanja razreda A+ u proračunskoj potrošnji, javlja se i nepostojanje razreda A u stvarnim podacima o potrošnji, što ukazuje na potencijalnu razliku između proračunske i stvarne potrošnje energije za ove razrede. Najizraženija razlika odnosi se na energetske razred B gdje je očekivani broj zgrada prema proračunskoj potrošnji trebao biti 22, dok je stvarni broj takvih zgrada samo pet. Velika je razlika i u razredu D gdje je očekivani broj zgrada prema energetske certifikatima trebao biti 17, dok je stvarna potrošnja u ovaj razred svrstala 33 zgrade. Vjerojatno je većina zgrada koje su trebale pripadati razredu B zapravo pokazala potrošnju razreda D i stoga je nastalo ovo veliko odstupanje. Pozitivan znak i za proračunsku i za stvarnu potrošnju je da nema zgrada u razredu G pa se može zaključiti da niti jedna škola nema vrlo nisku energetske učinkovitost. Prema navedenom, zgrade možda ne postižu očekivane razine energetske učinkovitosti kao što pokazuju njihove energetske certifikati.

Analiza sustava grijanja škola pokazala je da 80 % (75 od 94) škola koristi sustav centralnog grijanja na plin, dok 20 % (19 od 94) koristi sustav daljinskog grijanja (Slika 17).



Slika 17 Udio vrsta sustava grijanja u analiziranim školama


Budući da uzorak uključuje i male područne škole u Osječko-baranjskoj županiji, nepostojanje sustava daljinskog grijanja izazvano je ograničenim pristupom infrastrukturi daljinskog grijanja. Infrastruktura daljinskog grijanja se češće nalazi u urbanim ili gusto naseljenim područjima, gdje ju je ekonomski izvedivo uspostaviti i održavati jer implementacija infrastrukture daljinskog grijanja u ruralnim ili rijetko naseljenim regijama može biti pretjerano skupa. Male škole s ograničenim financijama mogu smatrati praktičnijim ulaganje u plinske sustave centralnog grijanja, unatoč njihovoj nižoj dugoročnoj učinkovitosti i prihvatljivosti za okoliš. Nadalje, u regijama koje karakterizira raštrkana populacija, potreba za daljinskim grijanjem možda neće doseći razinu koja opravdava dodjelu sredstava za razvoj potrebne infrastrukture.

5.4.2. Analiza energetske jaza


Energetski jaz se definira kao razlika između izmjerene i izračunate potrošnje energije zgrade [163, 177]. Unatoč različitim pristupima analizi energetske jaza, izračun kao razlika u potrošnji stvarne i proračunske energije kao udio proračunske potrošnje za određenu zgradu široko je prihvaćen pristup u literaturi i također je usvojen u ovom istraživanju [167, 178]:

$$\text{energetski jaz [\%]} = \frac{\text{stvarna potrošnja} - \text{proračunska potrošnja}}{\text{proračunska potrošnja}} \cdot 100 \quad (6)$$

Slika 18 prikazuje proračunsku i stvarnu potrošnju toplinske energije za grijanje svih 94 škola, dok slika 19 prikazuje energetski jaz izračunat prema formuli (6).



Slika 18 Proračunska i stvarna potrošnja toplinske energije za grijanje za uzorak škola



Slika 19 Energetski jaz u uzorku škola

Provedena je i deskriptivna statistička analiza energetskega jaza (Tablica 37), uzimajući u obzir vrstu škole (Tablica 38) te vrstu grijanja (Tablica 39).

Tablica 37 Deskriptivna statistička analiza energetskega jaza

Varijable	N	Aritmetička sredina	Medijan	Min.	Max.	Donji kvartil	Gornji kvartil
Energetski jaz [%]	94	71,73	42,11	-99,67	384,69	-14,96	136,40

Tablica 38 Deskriptivna statistička analiza energetskega jaza prema vrsti škole

Varijabla	Vrsta škole	N	Aritmetička sredina	Medijan	Min.	Max.	Donji kvartil	Gornji kvartil
Energetski jaz [%]	Osnovna	81	136,40	71,53	42,16	-99,67	384,69	-20,87
	Srednja	13	110,65	72,93	22,56	-2,66	226,95	6,96

Tablica 39 Deskriptivna statistička analiza energetskega jaza prema vrsti grijanja

Varijabla	Vrsta grijanja	N	Aritmetička sredina	Medijan	Min.	Max.	Donji kvartil	Gornji kvartil
Energetski jaz [%]	Daljinsko	19	100,65	84,04	-2,66	384,69	13,49	188,98
	Plinsko	75	64,40	38,99	-99,67	346,10	-23,53	123,78

Na temelju rezultata može se vidjeti da rezultati energetskega jaza pokazuju širok raspon pozitivnih i negativnih odstupanja. Pozitivna odstupanja u rezultatima energetskega jaza označavaju slučajeve kada zgrade troše više energije nego što je to prvotno procijenjeno prema energetskim certifikatima. Također, pozitivna odstupanja su znatno veća i češća od negativnih. To upućuje na zaključak da većina zgrada troši više energije nego što je to prvotno bilo predviđeno prema izračunima energetskih certifikata. Pozitivna odstupanja ističu područja gdje bi poboljšanja energetske učinkovitosti mogla biti potrebna kako bi se stvarna potrošnja energije uskladila s očekivanim razinama.

Dodatno, izračunat je i trošak za toplinsku energiju za grijanje koji nastaje zbog energetskega jaza. Cijene su dobivene od službenih distributera energije za daljinsko grijanje i plin za lokaciju Osijek (0,0236 €/kWh za daljinsko grijanje i 0,0403 €/kWh za plin) [272, 273]. Procjenjuje se da je prosječan godišnji trošak toplinske energije za grijanje zbog energetskega jaza veći za 2048,74 €. To znači da zgrade u prosjeku troše oko 2000 € više godišnje na grijanje nego što je predviđeno zbog jaza između proračunske i stvarne potrošnje energije.

5.4.3. Analiza uzroka pojave energetske jaz


Faktori koji pridonose prekomjernoj potrošnji mogu uključivati neučinkovitu opremu, lošu izolaciju, ponašanje korisnika ili promjene u obrascima korištenja koje nisu bile uzete u obzir u početnim procjenama energetske certifikata. Ukupno, prosječan energetske jaz utvrđen je na razini od 71 %, što je u skladu s vrijednostima energetske jaz utvrđenim u literaturi, primjerice 60-70 % za škole i 70-85 % za sveučilišta [169, 182]. Konzistentnost između utvrđenog energetske jaz i nalaza iz literature naglašava raširenost energetske jazova u obrazovnim zgradama i ističe potrebu za ciljanom intervencijom radi poboljšanja energetske učinkovitosti i smanjenja tih jazova.

Osnovne i srednje škole pokazuju slične prosječne vrijednosti energetske jaz (71,53 % i 72,93 %), ali osnovne škole imaju širi raspon i veću varijabilnost. Osnovne škole pokazuju veću varijabilnost vrijednosti energetske jaz u usporedbi sa srednjim školama. To bi moglo biti posljedica šireg raspona starosti, veličina i razina održavanja zgrada osnovnih škola, što dovodi do većih razlika u energetske učinkovitosti. Osnovne škole mogu biti raznolikih veličina kao što je prethodno i utvrđeno analizom širokog raspona površina među školama u uzorku, od manjih ruralnih područnih škola do velikih gradskih. Veće škole mogu imati složenije sustave grijanja i hlađenja, koji su podložniji energetske gubicima ako nisu pravilno održavani. Razlike u razini održavanja također doprinose ovoj varijabilnosti. Osim toga, osnovne škole obično imaju kraći dnevni raspored korištenja prostora u usporedbi sa srednjim školama, ali i specifične aktivnosti, poput dvoranskih sportova ili cjelodnevnih boravaka, mogu utjecati na stvarnu potrošnju energije. Srednje škole, iako pokazuju manju varijabilnost, imaju nešto viši prosječni energetske jaz. To može biti povezano s većim energetske zahtjevima zbog složenijih obrazovnih aktivnosti, uključujući laboratorije, radionice i informatičke učionice koje troše više energije. Srednje škole su često smještene u zgradama građenima tijekom razdoblja s nižim standardima energetske učinkovitosti, a sustavi grijanja, ventilacije i klimatizacije u ovim zgradama možda nisu adekvatno modernizirani.

Analiza energetske jaz kod različitih vrsta grijanja pokazuje značajne razlike između sustava daljinskog grijanja i plinskog grijanja, pri čemu su vrijednosti energetske jaz za daljinsko grijanje znatno više i varijabilnije. Konkretno, prosječan energetske jaz za daljinsko grijanje iznosi 100,65 %, dok je medijan 84,04 %. S druge strane, prosjek za plinsko grijanje iznosi 64,40 %, a medijan svega 38,99 %. Ovo ukazuje na to da zgrade koje koriste daljinsko grijanje općenito troše značajno više energije u odnosu na procjene u energetske certifikatima, u usporedbi s onima koje koriste plinsko grijanje. Razlozi za ove razlike mogu biti višestruki. Sustavi daljinskog grijanja obično se nalaze u urbanim područjima koja karakterizira širok raspon tipova i starosti zgrada. Zgrade spojene na mreže daljinskog grijanja često uključuju starije

objekte sa slabijom toplinskom izolacijom ili lošim održavanjem, što može značajno povećati stvarnu potrošnju energije. Osim toga, tehnologije i izvori energije koji se koriste u daljinskom grijanju također mogu biti vrlo raznoliki – od modernih, visoko učinkovitih sustava do zastarjelih postrojenja koja ne optimiziraju isporuku toplinske energije. S druge strane, sustavi plinskog grijanja su češće instalirani u individualnim zgradama, što omogućuje veću kontrolu nad energetsom učinkovitošću i boljim održavanjem opreme. Ovi sustavi često uključuju modernije kotlove i izolacijske tehnologije, posebno u novijim zgradama, što pridonosi smanjenju jaza između očekivane i stvarne potrošnje energije. Nadalje, velik energetska jaz kod daljinskog grijanja može odražavati i tehničke gubitke unutar samog distribucijskog sustava. Distribucijske mreže, osobito u starijim sustavima, mogu imati značajne toplinske gubitke tijekom prijenosa energije od centralnog postrojenja do krajnjih korisnika, a nisu obuhvaćeni izračunima u energetske certifikatima, ali imaju izravan utjecaj na stvarnu potrošnju energije. Visoka varijabilnost u vrijednostima energetske jaza kod daljinskog grijanja također može odražavati neujednačenost u kvaliteti energetske sustava među različitim zgradama spojenima na istu mrežu. Na primjer, dok moderni objekti mogu koristiti energiju učinkovito, starije zgrade u istoj mreži često doprinose znatno većem ukupnom energetske jazu.

Također, analiza je pokazala da je 66 od ukupno 94 analiziranih škola (70 %) imalo energetska jaz veći od 30 %. Analizom godine izgradnje škola koje su pokazale takve vrijednosti može se vidjeti da je velik broj tih zgrada, tj. 45 od ukupno 66 (68,2 %) izgrađen prije 1980. godine, prije sustavne implementacije zakonodavstva o toplinske izolaciji zgrada što je prikazano na slici 20. Na slici 20 korišteni su isti vremenski rasponi kao i u slici 2 kako bi se održala dosljednost.



Slika 20 Broj školskih zgrada s vrijednostima energetske jaze iznad 30 % prikazan prema godinama izgradnje

To ukazuje da je energetska jaza znatno izraženija u starijim zgradama što naglašava važnost njihove obnove s obzirom na to da će se takve zgrade koristiti još mnogo godina, posebno zbog njihove obrazovne namjene i važnosti zdravlja, sigurnosti i udobnosti korisnika. Osim toga, rezultati vezani uz starost zgrada ističu i potrebu za poboljšanjem izdavanja energetskih certifikata uzimajući u obzir starenje građevinskih materijala, budući da se trenutačne vrijednosti koeficijenta prolaska topline izračunavaju koristeći standardne vrijednosti za svaki materijal kao da je zgrada nova, što rezultira netočnim rezultatima. Ovo je posebno važno jer je dokazano da čak i male promjene u koeficijentu prolaska topline, jednom od najosjetljivijih parametara za predviđanje potrošnje energije, dovode do značajnih promjena u potražnji za grijanjem [274-276]. Također je utvrđeno da razlike između vrijednosti koeficijenta prolaska topline izmjerenih na terenu različitim metodama i teorijskih vrijednosti mogu iznositi i do 153 % [274, 277]. Rezultati ovog istraživanja također su u skladu s nekoliko drugih istraživanja koja pokazuju da zgrade s višim energetske razredom imaju znatno veće vrijednosti energetske jaze u usporedbi sa zgradama nižih razreda [168, 275, 278]. Konkretno, zgrade razreda A i B pokazale su prosječan energetska jaza „rebound“ efekta od 199,46 % i 180,41 %, dok su zgrade razreda E i F pokazale prosječan energetska jaza „prebound“ efekta od 30,53 % i 32,28 %.

5.4.4. Zaključak

Analiza energetske performansi u proučavanim obrazovnim zgradama otkrila je značajna odstupanja između očekivane i stvarne potrošnje energije, s prosječnim energetske jazom od 71 %. Ovi rezultati su u skladu s prethodnim istraživanjima koja su izvijestila o energetske jazu u obrazovnim zgradama u rasponu od 60 % do 85 %. Rezultati su također ukazali na značajne financijske posljedice ovih razlika, osobito u troškovima grijanja, gdje godišnja razlika iznosi prosječno oko 2000 €. Također provedeno istraživanje ukazuje da energetske certifikati zgrada možda ne odražavaju točno toplinske karakteristike starijih zgrada. Budući da su većina analiziranih zgrada starije od 40 godina, materijali koji su korišteni su se degradirali, ali proračuni toplinske propusnosti u energetske certifikatima temelje se na teorijskim vrijednostima koje pretpostavljaju nove materijale.

6. RAZVOJ SUSTAVA PROCJENE STANJA ŠKOLSKIH ZGRADA

6.1. Prikupljanje i analiza podataka za razvoj sustava procjene stanja školskih zgrada

Osim do sada već spomenutih podataka o potrošnji energije za svaku zgradu, ISGE sustav također sadrži informacije o godini izgradnje, konstrukcijskim elementima zgrada i njihovim specifikacijama. Ovi podaci prikupljeni su iz 166 osnovnih i srednjih škola u Osječko-baranjskoj županiji. Svaka zgrada ima informacije o materijalu: vrata i prozora, vanjskih zidova, konstrukcije krova, pokrova krova te poda. Budući da unos podataka ovisi o odgovornosti upravitelja zgrada, utvrđeno je da za neke zgrade nedostaju određeni podaci. Nedostajući podaci popunjeni su korištenjem *Metodologije provođenja energetskeg pregleda zgrada*, koja prikazuje karakteristične konstrukcijske elemente za određena razdoblja gradnje [279]. Stoga su, prema razdoblju izgradnje zgrade, nedostajući podaci popunjeni karakterističnim materijalima korištenim u tom razdoblju.

Budući da je materijal naveden za svaki element, njihov vijek trajanja analiziran je korištenjem vrijednosti održivog vijeka uporabe građevinskih elemenata. Ove vrijednosti dobivene su iz tablica o održivom vijeku uporabe građevinskih elemenata navedenih u hrvatskom *Pravilniku o metodama procjene vrijednosti nekretnina (NN 105/15)* [280]. Koristeći dostupne podatke o održivom vijeku uporabe za škole [280] i njihovoj godini izgradnje, izračunat je preostali vijek trajanja svake škole. Također, koristeći podatke o održivom vijeku uporabe za svaki materijal predstavljen u analiziranim građevinskim elementima i godini izgradnje škole, izračunat je preostali vijek uporabe svakog elementa. Prilikom izračuna preostalog vijeka uporabe elemenata uzeta je u obzir godina renovacije ako je određeni element bio obnovljen.

Građevinski elementi uzeti u obzir za ocjenjivanje stanja zgrade bili su: starost zgrade, vrata, prozori, vanjski zidovi, krov, pokrov krova i pod. Održivi vijek uporabe svakog analiziranog elementa prema materijalu prikazan je u tablici 40 [280].

Tablica 40 Održivi vijek uporabe analiziranih elemenata [280]

Element	Materijal	Održivi vijek uporabe [god]
Starost škole	-	70
Prozori	Drvo	40
	PVC	50

		Aluminij	50
		Miješano	45
Konstrukcija krova		Beton	100
		Drvo	120
Pokrov krova		Lim	35
		Salonit	40
		Crijep	50
		Bitumen	30
Vanjska vrata		Drvo	40
		PVC	50
		Aluminij	50
		Miješano	45
Vanjski zidovi		Armirani beton	70
		Armirani beton i opeka	80
		Opeka	90
		Kamen	80
Podna konstrukcija		Opeka	90
		Armirani beton	100
		Armirani beton i opeka	95
		Drvo	80
		Kamen	100

S obzirom na to da postoje različiti preostali održivi vijekovi uporabe svakog od analiziranih elemenata, ljestvica korištena za ocjenjivanje prikazana je u tablici 41.

Tablica 41 Ljestvica za ocjenjivanje elemenata

Kategorija stanja	Preostali vijek uporabe	Lingvistički prikaz
1	< 0 %	propalo
2	0 - 25 %	loše
3	25 - 50 %	zadovoljavajuće
4	50 - 75 %	dobro
5	75 - 100 %	izvrsno

Ove ukupne ocjene dalje se koriste kao baza podataka u sljedećim poglavljima za treniranje modela umjetnih neuronskih mreža i modela koji koristi algoritam nasumične šume kako bi se predvidjela ukupna ocjena škole.

Provedena je deskriptivna statistička analiza koja se odnosi na godinu izgradnje i obnove, zajedno sa starošću od izgradnje i obnove, za uzorak škola, a rezultati su prikazani u tablici 42.

Tablica 42 Deskriptivna statistička analiza starosti izgradnje i obnove za uzorak škola

Varijabla	N	Aritm. sredina	Min.	Maks.	Donji kvartil	Gornji kvartil	St. dev.
Godina izgradnje	166	1972,61	1900	2022	1959	1994	27,82
Godina zadnje obnove	123	2012,33	1991	2023	2006	2019	7,64
Starost od izgradnje	166	51,39	2	124	30	65	27,82
Starost od obnove	123	11,68	1	33	5	18	7,64

Skup podataka obuhvaća 166 škola s prosječnom godinom izgradnje 1972,61, što pokazuje da su mnoge škole građene početkom 1970-ih. Najstarija škola datira iz 1900. godine, dok je najnovija izgrađena 2022. godine, što pokazuje širok raspon starosti zgrada. Donji kvartil vrijednosti od 1959. godine sugerira da je 25 % škola izgrađeno prije ove godine, dok gornji kvartil od 1994. godine označava da je još 25 % škola izgrađeno nakon te godine. Visoka standardna devijacija od 27,82 godine odražava široku varijaciju u godinama izgradnje. Što se tiče obnova, podaci su dostupni za 123 škole, s prosječnom godinom posljednje obnove 2012,33. Obnove se kreću od 1991. do 2023. godine, što ističe škole koje nisu obnovljene desetljećima i one koje su nedavno obnovljene. Donji kvartil od 2006. godine i gornji kvartil od 2019. godine sugeriraju da su mnoge škole prošle obnovu relativno nedavno ili prije značajnog vremena. Prosječna starost od izgradnje je 51,39 godina, pri čemu se starost škole kreće od 2 do 124 godine, a standardna devijacija od 27,82 godine ponovno ukazuje na značajan raspon. Nasuprot tome, prosječna starost od posljednje obnove iznosi 11,68 godina, s rasponom od 1 do 33 godine i standardnom devijacijom od 7,64 godine, što je manje raspršeno u usporedbi s podacima o izgradnji. Naglašena je raznolikost u starosti školskih zgrada, pri čemu su neke nedavno izgrađene ili obnovljene, dok druge možda već zahtijevaju obnovu.

Također, u tablici 43 provedena je deskriptivna statistička analiza preostalog održivog vijeka uporabe analiziranih elemenata za uzorak škola.

Tablica 43 Deskriptivna statistička analiza preostalog održivog vijeka uporabe analiziranih elemenata u uzorku škola

Varijabla – Preostali održivi vijek korištenja	N	Aritmetička sredina	Minimum	Maksimum	Donji kvartil	Gornji kvartil	St. dev.
Starost zgrade	166	18,61	-54	68	5	40	27,82
Prozori	166	11,13	-84	46	-5	34	30,17
Krovna konstrukcija	166	64,64	-4	110	49	86	28,10
Pokrov krova	166	3,10	-74	46	-20	27	29,60
Vanjska vrata	166	8,56	-84	46	-6	31	29,26
Vanjski zidovi	166	36,93	-34	88	23	59	27,65
Podna konstrukcija	166	46,81	-44	98	35	70	32,18

Varijabla starost zgrade, koja uključuje podatke za 166 škola, pokazuje prosječan preostali održivi vijek uporabe od 18,61 godina. Međutim, postoji velika razlika s minimalnom vrijednošću od -54 i maksimalnom od 68, što ukazuje na to da su neke zgrade već znatno premašile svoj očekivani održivi vijek, dok druge još imaju značajno vrijeme do isteka. Donji kvartil je pet godina, što znači da 25 % zgrada ima pet ili manje godina preostalog održivog vijeka, dok gornji kvartil iznosi 40 godina, što znači da drugih 25 % ima više od 40 godina preostalog vijeka. Visoka standardna devijacija od 27,82 naglašava široku varijaciju u podacima. Što se tiče specifičnih elemenata, preostali održivi vijek se značajno razlikuje: prozori imaju prosječno 11,13 godina, ali se kreću od -84 do 46 godina, s visokom standardnom devijacijom od 30,17, što sugerira da neki već odavno trebaju zamjenu. Krovna konstrukcija ima najveći prosječni preostali vijek trajanja od 64,64 godine, s minimalnim trajanjem od -4 i maksimalnim od 110 godina, te donjim kvartilom od 49 i gornjim kvartilom od 86 godina.

S druge strane, krovni pokrov je osjetljiviji, s prosječnim preostalim vijekom trajanja od samo 3,10 godina i rasponom od -74 do 46 godina, što ukazuje na moguće probleme koji zahtijevaju hitnu pažnju. Vanjska vrata i zidovi pokazuju sličan obrazac varijabilnosti, s prosjecima od 8,56 i 36,93 godina, te značajnim standardnim devijacijama (29,26 za vrata i 27,65 za zidove). Podna konstrukcija ima aritmetičku sredinu od 46,81 godine preostalog vijeka, ali opet široki raspon (-44 do 98 godina) i visoka standardna devijacija od 32,18 upućuju na značajnu varijabilnost. Rezultati provedene deskriptivne statističke analize sugeriraju da, iako su neki dijelovi školskih zgrada u dobrom stanju, drugi su značajno oštećeni i zahtijevaju hitan popravak ili zamjenu.

6.2. Procjena stanja na razini elemenata

Nakon što je određen preostali vijek uporabe svakog elementa, bilo je moguće ocijeniti svaki element i dobiti ukupnu ocjenu svake škole kao prosječnu vrijednost svih ocjena elemenata. Ukupna ocjena izračunata je koristeći Excel radi jednostavnosti korištenja [201]. Tablica 44 prikazuje učestalost svake kategorije stanja od 1 do 5 za svaki element.


Tablica 44 Učestalost kategorija stanja među elementima

Kategorija stanja	Starost zgrade	Prozori	Krovna konstrukcija	Pokrov krova	Vanjska vrata	Vanjski zidovi	Podna konstrukcija
1	29	47	5	68	51	17	18
2	29	23	13	17	30	22	7
3	27	20	41	21	20	49	50
4	18	45	67	39	42	56	63
5	63	31	40	21	23	22	28

Starost zgrada pokazuje značajan broj zgrada u najboljem (63 u kategoriji 5) i najlošijem (29 u kategoriji 1) stanju. Slično tome, stanje prozora varira, s velikim brojem u najlošijoj kategoriji (47), ali i značajnim brojem u dobrom stanju (45 u kategoriji 4). Krovna konstrukcija i pokrov krova pokazuju zabrinjavajuće rezultate, posebno u nižim kategorijama, što sugerira dotrajalost tih elemenata, a posebno se ističe 68 pokrova krova u kategoriji 1, što ukazuje na jako loše stanje. Učestalost kategorija za vanjska vrata i zidove također pokazuje varijabilnost, s velikim brojem u nižim i višim kategorijama stanja. Podna konstrukcija se čini nešto boljom, s većom učestalošću u srednjim do višim kategorijama (50 u kategoriji 3 i 63 u kategoriji 4).

Nadalje, pomoću ocjena elemenata izračunata je ukupna ocjena svake škole, a rezultati izračuna ukupne ocjene prikazani su na slici 21 i u tablici 45. Ukupno stanje zgrade izračunato je kao aritmetička sredina ocjena stanja dobivenih za svaki element. Važno je naglasiti da se kategorija stanja 1, koja podrazumijeva preostali vijek trajanja manji od 0 %, odnosi na elemente koji su premašili svoj održivi vijek korištenja.

UKUPNA OCJENA ŠKOLE



Slika 21 Učestalost svake od ocjena među analiziranim školama

Tablica 45 Učestalost svake od ocjena među analiziranim školama

Kategorija stanja	Ukupna ocjena škole
1	15
2	47
3	46
4	37
5	21

Prema podacima, 15 škola ima najnižu ocjenu 1, što ukazuje na značajne nedostatke kod više elemenata zgrade. Najveći broj škola, njih 47, ima ukupnu ocjenu 2, što sugerira da je značajan dio zgrada u lošem stanju. Kategorija s ocjenom 3 obuhvaća 46 škola, što predstavlja sredinu u kojoj su zgrade općenito u zadovoljavajućem stanju, ali s prostorom za poboljšanja. Nadalje, 37 škola dobilo je ocjenu 4, što znači da su te zgrade u relativno dobrom stanju, s većinom komponenti vjerojatno dobro održavanih. Najviša ocjena 5 obuhvaća 21 školu, što pokazuje manju skupinu zgrada u izvrsnom stanju.

6.3. Varijable za razvoj modela procjene stanja školskih zgrada

Za razvoj modela umjetnih neuronskih mreža i modela nasumične šume za predviđanje ukupne ocjene stanja školske zgrade, ulazne varijable određene su kao preostali vijek trajanja svakog elementa, bez ocjenjivanja svakog pojedinog elementa. Ulazne i izlazne varijable prikazane su u tablici 46.

Tablica 46 Ulazne i izlazne varijable za razvoj modela procjene stanja školskih zgrada.

Vrsta varijable		Varijabla – preostali održivi vijek uporabe	Oznaka	Mjerna jedinica
Ulazna	Kontinuirana	Starost zgrade (engl. <i>Age of building</i>)	<i>Age</i>	godina
		Prozori (engl. <i>Windows</i>)	<i>Win</i>	
		Konstrukcija krova (engl. <i>Roof construction</i>)	<i>Roc</i>	
		Pokrov krova (engl. <i>Roof coverage</i>)	<i>Rcv</i>	
		Vanjska vrata (engl. <i>External doors</i>)	<i>Drs</i>	
		Vanjski zidovi (engl. <i>External walls</i>)	<i>Wal</i>	
		Podna konstrukcija (engl. <i>Floor construction</i>)	<i>Flr</i>	
Izlazna	Kategorička	Ukupna ocjena zgrade (engl. <i>Building total grade</i>)	<i>Btg</i>	1,2,3,4,5

Preostali održivi vjekovi uporabe pokazali su visoku korelaciju s izlaznom varijablom, što je vidljivo u tablici 47

Tablica 47 Korelacije ulaznih varijabli s izlaznom varijablom *Btg*

Varijabla	<i>Age</i>	<i>Win</i>	<i>Roc</i>	<i>Rcv</i>	<i>Drs</i>	<i>Wal</i>	<i>Flr</i>
<i>Btg</i>	0,834382	0,714653	0,820049	0,666845	0,823626	0,792957	0,739887

Sve korelacije su vrlo značajne, što pokazuju njihove visoke vrijednosti i crvene oznake. Označene korelacije imaju razinu značajnosti od $p < 0,05$.


Početni skup podataka podijeljen je na dva dijela nasumično: skup za treniranje, koji je korišten za izradu ili razvoj modela, i skup za validaciju, koji je služio isključivo za procjenu pogrešaka razvijenih modela. Skup za treniranje sadrži podatke za 117 školskih zgrada, što čini 70,5 % od ukupno 166 školskih zgrada, dok skup za validaciju obuhvaća 49 školskih zgrada, odnosno 29,5 % od ukupnog broja.

U sljedećim poglavljima prikazani su razvijeni modeli za procjenu stanja školskih zgrada, odnosno ukupne ocjene školskih zgrada koristeći umjetne neuronske mreže i algoritam nasumične šume.

Umjetne neuronske mreže su do sada korištene u samo tri rada vezana uz procjenu stanja zgrada [41, 42, 281], dok algoritam nasumične šume još nije korišten za procjenu stanja zgrada, unatoč širokoj primjeni u području energetske učinkovitosti zgrada [282-287].

6.4. Razvijeni model procjene stanja školskih zgrada pomoću umjetne neuronske mreže

Za razvoj modela korišten je MLP tip umjetne neuronske mreže. Slika 22 prikazuje arhitekturu optimalno odabranog modela za predviđanje ukupne ocjene stanja školskih zgrada.



Slika 22 Optimalni odabrani model za predviđanje ukupne ocjene školskih zgrada (MLP 7-11-5)

6.5. Razvijeni model procjene stanja školskih zgrada pomoću algoritma nasumične šume

S obzirom na to da je izlazna varijabla ukupna ocjena školske zgrade od 1 do 5, korišten je RF algoritam za klasifikaciju. Vrijednosti važnosti prediktora za RF model ukazuju na to koliko je svaka varijabla utjecajna u predviđanju izlazne varijable, u ovom slučaju ukupne ocjene školske zgrade. Broj stabala odabran je na 100. U literaturi je navedeno da je najveći dobitak u izvedbi postignut kada se trenira prvih 100 stabala [269]. Tablica 48 prikazuje važnosti prediktora ulaznih varijabli. Ove vrijednosti obično su normalizirane tako da najvažnija varijabla ima važnost 1.

Tablica 48 Važnosti prediktora ulaznih varijabli

Varijabla	Rang varijable	Važnost
<i>Roc</i>	100	1,000000
<i>Wal</i>	93	0,929054
<i>Drs</i>	87	0,874778
<i>Win</i>	81	0,805458
<i>Flr</i>	78	0,779996
<i>Age</i>	76	0,762153
<i>Rcv</i>	69	0,687752

6.6. Usporedba točnosti razvijenih modela procjene stanja školskih zgrada

Točnosti razvijenih modela ocijenjene su pomoću izraza korištenih za izračun statističkih tehnika za procjenu pogreške predviđanja prethodno prikazanih u tablici 18.

Tablica 49 prikazuje točnosti razvijenih modela procjene stanja školskih zgrada u skupu podataka za trening.

Tablica 49 Točnosti razvijenih modela procjene stanja školskih zgrada u skupu podataka za trening

R. br.	Zavisna varijabla	Vrsta modela	R^2	MSE	RMSE	CVRMSE	MAPE
1	<i>Btg</i>	ANN	0,987	0,017	0,131	4,35 %	0,50 %
2		RF	0,924	0,094	0,307	10,28 %	2,99 %

Komparativna izvedba ANN i RF modela pokazuje prikladnost naprednih metoda strojnog učenja za procjenu stanja zgrada. ANN model pokazuje superiornu prediktivnu točnost, s R^2 od 0,987 i MAPE od 0,50 %, što ukazuje na gotovo savršeno usklađivanje sa stvarnim ocjenama. S druge strane, RF model iako zadovoljavajuće izveden ($R^2 = 0,924$), pokazuje više vrijednosti pogrešaka, poput MAPE od 2,99 %. Ovi rezultati sugeriraju da, iako se oba modela mogu koristiti za BCA, ANN pruža pouzdaniji okvir za precizno predviđanje ocjena. Tablica 50 prikazuje točnosti razvijenih modela procjene stanja školskih zgrada u skupu podataka za validaciju.

Tablica 50 Točnosti razvijenih modela procjene stanja školskih zgrada u skupu podataka za validaciju

R. br.	Zavisna varijabla	Vrsta modela	R^2	MSE	RMSE	CVRMSE	MAPE
1	<i>Btg</i>	ANN	0,940	0,082	0,286	9,33 %	2,55 %
2		RF	0,942	0,086	0,292	9,72 %	2,66 %

Rezultati validacije također naglašavaju superiornu prediktivnu sposobnost ANN modela za ocjenu ukupne ocjene zgrade. S $R^2 = 0,940$ i MAPE od 2,55 %, ANN postiže visoku točnost i malu pogrešku, čineći ga pouzdanim alatom za procjenu stanja zgrada. RF model, iako neznatno manje precizan ($R^2 = 0,942$, MAPE = 2,66 %), također pokazuje snažnu sposobnost generalizacije, što sugerira da je prihvatljiva alternativna ili komplementarna metoda.

6.7. Zaključak

Excel model omogućio je analizu na razini komponenti, čineći temelj za kasnije modele strojnog učenja. ANN i RF modeli koristili su podatke iz Excel sustava bodovanja za predviđanje ukupne ocjene zgrade. Excel sustav bodovanja nudi praktičan alat za početne procjene građevinskih elemenata, dok modeli ANN i RF pružaju detaljne, prediktivne analize potrebne za prioritiziranje renovacija. Rezultati su otkrili značajna odstupanja u stanju komponenti, osobito u elementima kao što su prozori i krovovi, koji su često premašili svoju očekivanu životnu dob, što sugerira sistemski problem u praksama održavanja ili

raspodjeli financijskih sredstava, gdje preventivno održavanje možda nije adekvatno prioritizirano ili financirano. Značajan aspekt analize bila je velika varijacija u dobi i povijesti renovacije zgrada gdje su rezultati pokazali da, dok su neke zgrade relativno nedavno građene ili renovirane, značajan broj je znatno stariji, a neke su starije od 100 godina. Ocjene stanja među školama, pri čemu značajan broj pripada u niže kategorije, naglašavaju hitnu potrebu za ciljanim intervencijama. Prevalencija loših ili srednjih ocjena u ključnim komponentama poput krovšta i prozora ne samo da odražava trenutačnu fizičku situaciju zgrada, već ima i šire implikacije na energetske učinkovitost i sigurnost.

7. VALIDACIJA RAZVIJENIH MODELA PROCJENE POTROŠNJE ENERGIJE, ENERGENATA I VODE I SUSTAVA PROCJENE STANJA ŠKOLSKIH ZGRADA

7.1. Uzorak za validaciju

Kao i za razvijanje modela, podaci o školama za validaciju modela dobiveni su od strane ISGE-a [288]. Za validaciju razvijenih modela koristit će se ukupno 40 škola, od čega će 20 biti iz kontinentalne Hrvatske, a 20 iz primorske.

Uključivanjem škola iz primorske Hrvatske, poput onih u obalnim i otočnim područjima, i škola iz kontinentalne Hrvatske, modeli će se testirati na razne urbane, ruralne i specifične regionalne klimatske uvjete. Na taj način, validacija će potvrditi koliko su modeli robusni i spremni za upotrebu u stvarnim uvjetima obrazovnog sustava diljem Hrvatske.

U županije kontinentalne Hrvatske pripadaju Grad Zagreb, Zagrebačka županija, Krapinsko-zagorska županija, Varaždinska županija, Koprivničko-križevačka županija, Međimurska županija, Bjelovarsko-bilogorska županija, Virovitičko-podravska županija, Požeško-slavonska županija, Brodsko-posavska županija, Osječko-baranjska županija, Vukovarsko-srijemska županija, Karlovačka županija i Sisačko-moslavačka županija.

U županije primorske Hrvatske pripadaju Primorsko-goranska županija, Ličko-senjska županija, Zadarska županija, Šibensko-kninska županija, Splitsko-dalmatinska županija, Istarska županija i Dubrovačko-neretvanska županija.

Iz uzorka za validaciju bit će izuzeta Osječko-baranjska županija s obzirom na to da su na uzorku škola iz nje razvijani svi modeli.

Popis korištenih škola za validaciju razvijenih modela, vrsta škole te županija kojima pripadaju nalazi se u tablici 51.

Tablica 51 Popis škola korištenih za validaciju razvijenih modela

R.Br.	Naziv škole	Vrsta škole	Županija
1	OŠ Ivane Brlić Mažuranić	Osnovna	Zagrebačka županija

2	SŠ Jastrebarsko	Srednja	Zagrebačka županija
3	OŠ Donja Stubica	Osnovna	Krapinsko-zagorska
4	OŠ Đurmanec	Osnovna	Krapinsko-zagorska
5	OŠ Vojnić	Osnovna	Karlovačka
6	OŠ Draganići	Osnovna	Karlovačka
7	III. OŠ Varaždin	Osnovna	Varaždinska
8	Graditeljska, prirodoslovna i rudarska škola Varaždin	Srednja	Varaždinska
9	OŠ Otona Ivekovića	Osnovna	Grad Zagreb
10	OŠ Mate Lovraka	Osnovna	Grad Zagreb
11	PŠ Peklenica	Osnovna	Međimurska
12	III Osnovna škola Bjelovar	Osnovna	Bjelovarsko-bilogorska
13	OŠ Antun Mihanović Slavonski Brod	Osnovna	Brodsko-posavska
14	SŠ Matija Antun Reljković Slavonski Brod	Srednja	Brodsko-posavska
15	PŠ Milanovac	Osnovna	Virovitičko-podravska
16	OŠ Josipa Kozarca	Osnovna	Virovitičko-podravska
17	OŠ Blage Zadre Vukovar	Osnovna	Vukovarsko-srijemska
18	PŠ Srijem	Osnovna	Koprivničko-križevačka
19	OŠ Fra Kaje Adžića	Osnovna	Požeško-slavonska
20	SŠ Glina	Srednja	Sisačko-moslavačka
21	Gimnazija Andrije Mohorovičića	Srednja	Primorsko-goranska
22	Srednja pomorska škola Bakar	Srednja	Primorsko-goranska
23	Područna škola Škrlevo	Osnovna	Primorsko-goranska
24	OŠ dr Jure Turića	Osnovna	Ličko-senjska
25	OŠ Plitvička Jezera	Osnovna	Ličko-senjska
26	SŠ Otočac	Srednja	Ličko-senjska
27	PŠ Bokanjac	Osnovna	Zadarska
28	OŠ Petra Preradovića	Osnovna	Zadarska
29	SŠ Gračac	Srednja	Zadarska
30	OŠ Jurja Dalmatinca	Osnovna	Šibensko-kninska
31	PŠ Ražine	Osnovna	Šibensko-kninska
32	OŠ Čista Velika	Osnovna	Šibensko-kninska
33	OŠ Bol	Osnovna	Splitsko-dalmatinska

34	OŠ Mejaši	Osnovna	Splitsko-dalmatinska
35	OŠ Stobreč	Osnovna	Splitsko-dalmatinska
36	PŠ Galižana	Osnovna	Istarska
37	Osnovna škola Kaštanjer Pula	Osnovna	Istarska
38	Gimnazija i strukovna škola Jurja Dobrile Pazin	Srednja	Istarska
39	OŠ Gruda	Osnovna	Dubrovačko-neretvanska
40	Ekonomska i trgovačka škola	Srednja	Dubrovačko-neretvanska

Za ocjenu performansi razvijenih modela na uzorku za validaciju korištene su prethodno spomenute metrike kojima su ocjenjivani i svi modeli tijekom razvijanja, a koji se nalaze u tablici 18. Primarno je promatran koeficijent determinacije R^2 kao metrika za vrednovanje modela. Chaddockova ljestvica koja pokazuje koliko dobro vrijednost koeficijenta determinacije R^2 opisuje model prikazana je u tablici 52.

Tablica 52 Chaddockova ljestvica [289]

Koeficijent determinacije R^2	Značenje
0,00	Odsutnost veze
0,00- 0,25	Slaba veza
0,25- 0,64	Veza srednje jakosti
0,64 – 1,00	Čvrsta veza
1,00	Potpuna veza

7.2. Validacija razvijenih modela procjene potrošnje električne energije

Na prethodno navedenom uzorku škola provedena je validacija oba razvijena modela procjene potrošnje električne energije s pomoću višestruke linearne regresije te s pomoću neuronskih mreža.

U tablici 53 nalazi se prikaz točnosti razvijenih modela procjene potrošnje električne energije u uzorku škola za validaciju.

Tablica 53 Točnosti razvijenih modela procjene potrošnje električne energije u uzorku škola za validaciju

Red. Br.	Vrsta modela	Zavisna varijabla	R^2	MSE	RMSE	CVRMSE	MAPE
1	MLR	AEC	0,681	1,66E+08	12872,9	30,25%	26,09%

2	NN		0,325	2,70E+08	16439,3	38,63%	34,14%
---	----	--	-------	----------	---------	--------	--------

Rezultati analize modela pokazuju da MLR ima znatno bolje performanse u usporedbi s NN. Prema koeficijentu determinacije (R^2), MLR postiže vrijednost od 0,681, što ukazuje na čvrstu vezu između nezavisnih i zavisne varijable *AEC*, budući da ljestvica pokazuje da vrijednosti iznad 0,64 označavaju čvrstu vezu. Nasuprot tome, NN ima R^2 od 0,325, što predstavlja vezu srednje jakosti, jer se nalazi u rasponu od 0,25 do 0,64. Osim toga, MLR ima niže vrijednosti MSE (1,66E+08), RMSE (12872,9), CVRMSE (30,25 %) i MAPE (26,09 %) u usporedbi s NN, koji ostvaruje MSE od 2,70E+08, RMSE od 16439,3, CVRMSE od 38,63 % i MAPE od 34,14 %. Ovi rezultati jasno pokazuju da je MLR model pouzdaniji za predikciju *AEC* u ovom uzorku podataka, dok NN pokazuje slabiju sposobnost objašnjenja varijacija i veću pogrešku. Prema svim analiziranim metrikama, MLR se preporučuje kao bolji izbor za ovu primjenu.

Razlika u performansama između MLR-a i NN-a može se objasniti prirodom podataka i karakteristikama ovih modela. MLR je linearan model koji pretpostavlja postojanje linearne veze između zavisne varijable *AEC* i nezavisnih varijabli. Ako su podaci uglavnom linearni ili približno linearni, MLR vrlo precizno modelira te odnose, što objašnjava njegov visok R^2 i niže greške (MSE, RMSE, CVRMSE, MAPE).

7.3. Validacija razvijenih modela procjene potrošnje vode

Na prethodno navedenom uzorku škola provedena je validacija sva četiri razvijena modela procjene potrošnje vode, gdje su dva modela razvijena za procjenu godišnje potrošnje vode jedan s pomoću višestruke linearne regresije te jedan s pomoću neuronskih mreža, a dva za procjenu mjesečne potrošnje vode također jedan s pomoću višestruke linearne regresije te jedan s pomoću neuronskih mreža.

U tablici 54 nalazi se prikaz točnosti razvijenih modela procjene godišnje i mjesečne potrošnje vode u uzorku škola za validaciju.

Tablica 54 Točnosti razvijenih modela procjene godišnje i mjesečne potrošnje vode u uzorku škola za validaciju

R. Br.	Vrsta modela	Zavisna varijabla	R^2	MSE	RMSE	CVRMSE	MAPE
1	MLR	YWC	-0,168	1,34E+05	366,42	48,70 %	46,25 %
2	ANN		0,785	4,52E+04	212,66	28,26 %	28,47 %
3	MLR	MWC	0,641	525,49	22,92	35,58 %	26,57 %

4	ANN		0,593	561,32	23,69	36,77 %	27,65 %
---	-----	--	-------	--------	-------	---------	---------

Rezultati za uzorak škola za validaciju godišnje i mjesečne potrošnje vode ukazuju na značajne razlike u performansama između višestruke linearne regresije (MLR) i neuronskih mreža (ANN), ovisno o zavisnoj varijabli. Kada se promatra godišnja potrošnja vode (YWC), ANN postiže daleko bolje rezultate od MLR-a. ANN ima R^2 od 0,785, što prema ljestvici ukazuje na čvrstu vezu između ulaznih varijabli i zavisne varijable, dok MLR postiže vrlo nisku vrijednost R^2 od -0,168, što ukazuje na odsutnu vezu. ANN također ima znatno niže greške (MSE, RMSE, CVRMSE, MAPE), primjerice, RMSE je 212,66 u usporedbi s 366,42 kod MLR-a, dok je MAPE kod ANN-a 28,47 %, što je značajno bolje od 46,25 % kod MLR-a.

Kod mjesečne potrošnje vode (MWC), razlika u performansama između MLR-a i ANN-a je manja. MLR postiže nešto bolji R^2 (0,641) u odnosu na ANN (0,593), što ukazuje na čvrstu vezu za MLR i vezu srednje jakosti za ANN. MLR također ima blago niže greške, primjerice RMSE od 22,92 u usporedbi s 23,69 kod ANN-a, kao i nešto niži MAPE (26,57 % naspram 27,65 %). To sugerira da je MLR pouzdaniji model za procjenu mjesečne potrošnje vode, dok ANN nema značajnu prednost u ovom slučaju.

Razlika u performansama ovih modela može se objasniti prirodom zavisnih varijabli. Godišnja potrošnja vode (YWC) može uključivati složenije i nelinearne obrasce koji bolje odgovaraju neuronskim mrežama, dok se mjesečna potrošnja vode (MWC) može bolje modelirati linearnim metodama poput MLR-a, zbog stabilnijih i jednostavnijih obrazaca. ANN modeli, iako teoretski moćniji, zahtijevaju više podataka i pažljivo podešavanje hiperparametara kako bi optimalno iskoristili nelinearne odnose, dok MLR bolje funkcionira s jednostavnim i linearnim obrascima. Zaključno, ANN se pokazao boljim za procjenu godišnje potrošnje, dok je MLR pouzdaniji za mjesečnu potrošnju.

7.4. Validacija razvijenih modela procjene potrošnje toplinske energije

Na prethodno navedenom uzorku škola provedena je validacija sva tri razvijena modela procjene potrošnje toplinske energije pomoću višestruke linearne regresije, neuronskih mreža te algoritma nasumične šume.

U tablici 55 nalazi se prikaz točnosti razvijenih modela procjene potrošnje toplinske energije u uzorku škola za validaciju.

Tablica 55 Točnosti razvijenih modela procjene potrošnje toplinske energije u uzorku škola za validaciju

R. br.	Vrsta modela	Zavisna varijabla	R^2	MSE	RMSE	CVRMSE	MAPE
--------	--------------	-------------------	-------	-----	------	--------	------

1	MLR	AHC	0,185	2,84E+10	168640,65	64,36 %	39,43 %
2	ANN		0,119	2,42E+10	155425,85	59,32 %	48,96 %
3	RF		0,174	2,98E+10	172501,61	65,84 %	47,34 %

Iz tablice je vidljivo da su sva tri razvijena modela procjene potrošnje toplinske energije postigla loše rezultate u uzorku škola za validaciju odnosno ako se promatra R^2 veza je za sva tri modela slaba, gotovo pa odsutna. Na temelju ovih rezultata zaključilo se da modeli procjene potrošnje toplinske energije nisu primjenjivi diljem Republike Hrvatske te se odlučilo modele testirati na drugačijem uzorku koji će uključivati samo škole iz istočnog dijela Hrvatske, odnosno Slavonije, a to su škole iz sljedećih županija: Brodsko-posavska županija, Požeško-slavonska županija, Virovitičko-podravska županija te Vukovarsko-srijemska županija. Iz uzorka će kao i prethodno biti izuzeta Osječko-baranjska županija s obzirom na to da su na uzorku škola iz nje razvijani svi modeli.

Popis korištenih škola istočne Hrvatske za validaciju razvijenih modela procjene potrošnje toplinske energije, vrsta škole te županija kojima pripadaju nalazi se u tablici 56.

Tablica 56 Popis korištenih škola istočne Hrvatske za validaciju razvijenih modela procjene potrošnje toplinske energije

R. Br.	Naziv Škole	Vrsta škole	Županija
1	OŠ Antun Mihanović Slavonski Brod	Osnovna	Brodsko-posavska
2	Ekonomsko-birotehnička škola Slavonski Brod	Srednja	Brodsko-posavska
3	OŠ "Dragutin Tadijanović" Slavonski Brod	Osnovna	Brodsko-posavska
4	PŠ Milanovac	Osnovna	Virovitičko-podravska
5	OŠ Josipa Kozarca	Osnovna	Virovitičko-podravska
6	OŠ "Vladimir Nazor", Virovitica	Osnovna	Virovitičko-podravska
7	PŠ Podgorje	Osnovna	Virovitičko-podravska
8	OŠ Blage Zadre Vukovar	Osnovna	Vukovarsko-srijemska
9	OŠ Nikole Andrića Vukovar	Osnovna	Vukovarsko-srijemska
10	OŠ Ivana Mažuranića, Vinkovci	Osnovna	Vukovarsko-srijemska
11	Ekonomska i trgovačka škola Ivana Domca Vinkovci	Osnovna	Vukovarsko-srijemska
12	OŠ Fra Kaje Adžića	Osnovna	Požeško-slavonska
13	OŠ fra Kaje Adžića, Pleternica	Osnovna	Požeško-slavonska
14	OŠ Zdenka Turkovića	Osnovna	Požeško-slavonska

Na uzorku škola istočne Hrvatske provedena je validacija sva tri razvijena modela procjene potrošnje toplinske energije s pomoću višestruke linearne regresije, neuronskih mreža te algoritma nasumične šume.

U tablici 57 nalazi se prikaz točnosti razvijenih modela procjene potrošnje toplinske energije u uzorku škola za validaciju iz istočne Hrvatske.

Tablica 57 Točnosti razvijenih modela procjene potrošnje toplinske energije u uzorku škola za validaciju iz istočne Hrvatske

R. br.	Vrsta modela	Zavisna varijabla	R^2	MSE	RMSE	CVRMSE	MAPE
1	MLR	AHC	0,890	4,90E+09	69992,11	25,66 %	20,94 %
2	ANN		0,314	1,71E+10	130601,75	47,88 %	34,59 %
3	RF		0,239	1,03E+10	101490,47	37,21 %	27,52 %

Kada su modeli testirani na uzorku škola iz istočne Hrvatske, vidljiva su značajna poboljšanja u performansama. MLR model je ostvario izuzetno visoku točnost s $R^2 = 0,890$, što ukazuje na vrlo dobru povezanost između ulaznih varijabli i potrošnje toplinske energije. MSE, RMSE i MAPE su znatno niži nego u prethodnim rezultatima, što sugerira da je MLR model sada puno bolje predviđao potrošnju toplinske energije. S druge strane, ANN i RF modeli također pokazuju poboljšanje u odnosu na prethodne rezultate, iako nisu postigli tako visoke performanse kao MLR. ANN je postigao $R^2=0,314$, a RF $R^2=0,239$. Iako ovi modeli imaju slabiju točnost u odnosu na MLR, njihova R^2 vrijednost i smanjenje pogrešaka ukazuju na to da su bolje prilagođeni ovom specifičnom uzorku.

Testiranje modela na uzorku škola iz istočne Hrvatske pokazuje mnogo bolje rezultate, osobito za MLR, čiji visoki R^2 i niski MAPE ukazuju na njegovu veliku primjenjivost za predviđanje potrošnje toplinske energije u ovom specifičnom geografskom području. Uz to, ANN i RF modeli, iako nisu postigli tako visoke rezultate, također pokazuju potencijal za poboljšanje i mogu biti korisni za daljnje analize, posebno uz dodatne optimizacije i prilagodbe za specifične uvjete u istočnom dijelu Hrvatske. U konačnici, ovi rezultati sugeriraju da bi za precizniju procjenu potrošnje toplinske energije bilo korisno koristiti modele razvijene na podacima specifičnim za određene regije, kao što je Slavonija, zbog različitih čimbenika koji mogu utjecati na potrošnju toplinske energije u različitim dijelovima Hrvatske.

U primorskoj Hrvatskoj, zbog specifičnih klimatskih uvjeta i infrastrukture, mnoge škole ne koriste centralizirane sustave grijanja na plin ili toplanu. Umjesto toga, često se koriste alternativni izvori

energije poput struje ili loživog ulja. Ovi energenti nisu toliko stabilni i ekonomski isplativi kao plin, a njihova potrošnja može varirati ovisno o mnogim faktorima, uključujući specifičnu infrastrukturu svake škole, tip sustava grijanja te vremenske uvjete. Također, električna energija i lož ulje mogu imati različite energetske karakteristike u odnosu na plin, što znači da modeli razvijeni za procjenu potrošnje toplinske energije potencijalno imaju poteškoće u preciznoj predikciji potrošnje, jer ti energenti mogu zahtijevati drugačiji pristup u modeliranju.

S druge strane, u istočnoj Hrvatskoj (posebno u Slavoniji), većina škola koristi plin ili centralizirane sustave grijanja (toplane), što omogućuje veću uniformnost u potrošnji energije. Zaključno, razlike u energentima koji se koriste za grijanje škola mogu značajno utjecati na točnost modela procjene potrošnje toplinske energije. Za učinkovitije modele potrebno je uzeti u obzir specifičnosti svakog energenta i prilagoditi modele prema različitim uvjetima grijanja u različitim dijelovima Hrvatske.

7.5. Validacija razvijenog sustava procjene stanja

Na prethodno navedenom uzorku škola (koji obuhvaća svih 40 škola) provedena je validacija razvijenog sustava za procjenu stanja.

U tablici 58 nalazi se prikaz točnosti razvijenih modela procjene stanja u uzorku škola za validaciju.

Tablica 58 Točnosti razvijenih modela procjene stanja u uzorku škola za validaciju

Red. Br.	Vrsta modela	Zavisna varijabla	R^2	MSE	RMSE	CVRMSE	MAPE
1	NN	<i>Btg</i>	0,799	0,200	0,447	18,44 %	7,71 %
2	RF		0,747	0,225	0,474	19,56 %	9,17 %

Iz tablice 63 može se vidjeti da su oba modela, umjetne neuronske mreže i algoritam nasumične šume, postigla vrlo dobre rezultate u procjeni ukupne ocjene zgrade škole (*Btg*) u uzorku od 40 škola. Model NN pokazuje vrlo visoku točnost s $R^2=0,799$, što ukazuje na čvrstu vezu između ulaznih varijabli i ukupne ocjene zgrade, objašnjavajući gotovo 80 % varijacije u podacima. Također, MSE od 0,200 i RMSE od 0,447 sugeriraju nisku srednju kvadratnu pogrešku, a visoki CVRMSE od 18,44 % i MAPE od 7,71 % ukazuju na vrlo precizna predviđanja u odnosu na stvarne vrijednosti. S druge strane, model nasumične šume također daje dobre rezultate s $R^2=0,747$, što znači da objašnjava 74,7 % varijacije u ukupnoj ocjeni zgrade, iako je nešto niže od NN modela. MSE od 0,225 i RMSE od 0,474 pokazuju nešto veće pogreške u predviđanjima u odnosu na NN, dok su CVRMSE i MAPE nešto viši (19,56 % i 9,17 %). Zaključno, iako

je NN model postigao bolju točnost u svim ključnim metrikama, RF model također daje vrlo dobre rezultate, čineći ga prikladnim za primjenu u procjeni ukupne ocjene zgrade škole.

7.6. Zaključak

Na temelju svih provedenih validacija razvijenih modela za procjenu potrošnje energije, uključujući električnu energiju, vodu i toplinsku energiju, kao i za procjenu ukupne ocjene stanja zgrade, mogu se donijeti ključni zaključci o učinkovitosti, primjenjivosti i preciznosti ovih modela u različitim uvjetima. Modeli su razvijeni pomoću različitih tehnika, uključujući višestruku linearne regresije (MLR), umjetne neuronske mreže (NN) i algoritam nasumične šume (RF), a njihova točnost testirana je na uzorku koji je obuhvaćao ukupno 40 škola - 20 škola iz kontinentalne Hrvatske i 20 škola iz primorske Hrvatske, dok su za toplinsku energiju modeli testirani posebno na istočnom dijelu Hrvatske zbog loših performansi u primarnom uzorku za validaciju.

Za predviđanje potrošnje električne energije, MLR se ističe kao najpouzdaniji model, s obzirom na njegovu sposobnost preciznog modeliranja linearnih veza među varijablama. Iako NN mogu biti moćne za složenije, nelinearne odnose, u ovom kontekstu nisu pružili jednak stupanj točnosti, što potvrđuje da za specifične vrste predviđanja, poput potrošnje električne energije, linearniji modeli mogu biti učinkovitiji.

Kod potrošnje vode, razlika između MLR-a i ANN-a bila je značajna, ovisno o tome je li riječ o godišnjoj ili mjesečnoj potrošnji. Za godišnju potrošnju, ANN je dala bolje rezultate, vjerojatno zbog nelinearnosti podataka koji uključuju sezonske varijacije i druge kompleksne faktore. S druge strane, MLR se pokazao preciznijim za mjesečne varijacije, gdje su obrasci potrošnje stabilniji i linearniji što ukazuje na važnost odabira modela koji najbolje odgovara prirodi i dinamici podataka koje se procjenjuju.

U kontekstu toplinske energije, značajan skok u performansama zabilježen je kada su modeli testirani na uzorku škola iz istočne Hrvatske, gdje su specifični uvjeti i geografija omogućili bolje prilagodbe modela. MLR se ponovno pokazao najboljim modelom, što može biti povezano s jačom linearnošću i manjom kompleksnošću odnosa među varijablama u ovom specifičnom kontekstu. No, i modeli poput ANN i RF pokazuju potencijal za daljnja poboljšanja, osobito uz dodatne optimizacije, iako njihova primjena u ovom kontekstu nije bila jednako učinkovita kao MLR.

Za procjenu stanja zgrade, oba modela, NN i RF, postigla su vrlo visoke performanse, s NN modelom koji je postigao nešto bolje rezultate u kontekstu R^2 i drugih metrika što potvrđuje da oba modela imaju

visoku prediktivnu moć, koja može biti korisna za donošenje odluka u vezi s potrebama za obnovom školskih zgrada.

S obzirom na sve rezultate, može se zaključiti da odabir modela u velikoj mjeri ovisi o vrsti predviđanja, specifičnostima podataka i ciljevima analize. MLR je najprikladniji za linearne odnose i jednostavnije obrasce, dok ANN pokazuje svoju prednost u složenijim, nelinearnim podacima, posebno u slučajevima poput procjene godišnje potrošnje vode. RF model se, pak, može koristiti kao alternativa kada su potrebna robusna predviđanja s većim brojem ulaznih varijabli ili kada se želi bolje razumjeti interakcije među varijablama. U svakom slučaju, svaka od metoda ima svoje mjesto u upravljanju školama, a njihova pravilna primjena može dovesti do značajnih ušteda i poboljšanja u učinkovitosti potrošnje energije i resursa.

Također, s obzirom na razlike između kontinentalne i primorske Hrvatske, kao i specifičnosti različitih dijelova zemlje, rezultati ove analize sugeriraju potrebu za razvojem modela specifičnih za određene regije, što može dodatno povećati točnost predviđanja i pružiti bolje smjernice za donošenje odluka pri uštedi energije.

8. ZAKLJUČAK, PRAKTIČNE SMJERNICE ZA UPRAVLJANJE IMOVINOM U SMISLU ENERGETSKE UČINKOVITOSTI I ODRŽIVOSTI ŠKOLSKIH ZGRADA I SMJERNICE ZA DALJNJA ISTRAŽIVANJA

8.1. Zaključak

Ovo istraživanje je provedeno na temelju prikupljenih povijesnih podataka o geometrijskim, uporabnim i materijalnim karakteristikama školskih zgrada u Osječko-baranjskoj županiji kao i o njihovoj potrošnji energije, energenata i vode te su razvijeni novi modeli procjene potrošnje energije, energenata i vode i sustav procjene stanja. Podaci korišteni za ovo istraživanje dobiveni su primarno od ISGE-a te iz energetske certifikata predmetnih zgrada, no s obzirom na određeni broj nedostajućih podataka u sustavu, dodatno su korišteni i godišnji planovi i programi rada škola koji su dostupni na internetskim stranicama svake od škola.

U doktorskom radu prikazani su rezultati provedenog istraživanja te važne spoznaje iz predmeta istraživanja. Ostvareni su postavljeni ciljevi istraživanja te su dokazane postavljene hipoteze. Istraživanjem je utvrđeno sljedeće:

- Moguće je prikupljanje povijesnih geometrijskih, uporabnih i materijalnih karakteristika školskih zgrada u Osječko-baranjskoj županiji. Za istraživanje su prikupljeni podaci o 195 školskih zgrada u Osječko-baranjskoj županiji. Iz ISGE-a te energetske certifikata prikupljeni su podaci o godini izgradnje, godini posljednje renovacije, broju korisnika zgrade (učenika i nastavnika), vrsti škole, korisnoj površini, volumenu zgrade, potrošnji električne energije, potrošnji toplinske energije, mjesečnoj i godišnjoj potrošnji vode te materijalima od kojih su izrađeni građevinski elementi škola. Navedeni podaci predstavljali su podlogu za stvaranje baze za analizu i provedbu istraživanja. Unatoč svim uložnim naporima i prikupljanju podataka s više strana, određeni podaci su ipak za određene škole bili nedostajući. Iz toga razloga za razvoj svakog od modela te za razvoj sustava procjene stanja primijenjen je različit uzorak iz ukupnog uzorka s obzirom na dostupnost podataka.
- Razvijeni su modeli procjene potrošnje električne energije: jedan koristeći višestruku linearnu regresiju i jedan koristeći neuronske mreže. Zaključilo se da su oba modela učinkoviti alati za predviđanje potrošnje električne energije. Analizom točnosti razvijenih modela koristeći metrike kao što su R^2 , MSE, RMSE, CVRMSE i MAPE ocijenjene su točnosti razvijenih modela te

je utvrđeno da su neuronske mreže postigle bolje rezultate na skupu podataka za trening dok je višestruka linearna regresija postigla bolje rezultate na skupu podataka za validaciju, no u oba slučaja se radi o malim prednostima u pogledu točnosti.

- Razvijena su dva modela procjene mjesečne potrošnje vode koristeći višestruku linearnu regresiju i neuronske mreže te dva modela procjene godišnje potrošnje vode također koristeći višestruku linearnu regresiju i neuronske mreže. Utvrđeno je da su oba modela učinkovita u predviđanju potrošnje vode s visokim R^2 vrijednostima koje ukazuju na jake korelacije između predviđene i stvarne potrošnje. Utvrđeno je da model višestruke linearne regresije bolje funkcionira u kontekstu MAPE vrijednosti za predviđanje godišnje potrošnje vode u skupu podataka za trening, a s druge strane, neuronske mreže pokazuje superiornost u većini drugih metrika, kao što su MSE, RMSE i CVRMSE, osobito u skupu podataka za validaciju, s boljim R^2 za godišnju potrošnju vode i nižim vrijednostima pogreške od regresije. Rezultati također ukazuju na važnost primjene oba modela u različitim scenarijima, ovisno o specifičnim ciljevima analize i korisnicima.
- Razvijena su tri modela procjene potrošnje toplinske energije, koristeći višestruku linearnu regresiju, neuronske mreže te algoritam nasumične šume. Usporedba točnosti razvijenih modela pokazala je značajne razlike u izvedbi između tri navedena modela. Iako je model algoritma nasumične šume ostvario zadovoljavajuće rezultate u trening skupu, njegov pad performansi na validacijskom skupu ukazuje na njegovu sklonost „overfittingu“. S druge strane, model neuronskih mreža je pokazao vrlo dobre rezultate, s R^2 od 0,943 na treningu i na validaciji ($R^2 = 0,888$). Iako je model neuronskih mreža precizniji od modela višestruke linearne regresije u većini mjerenja, njegova složenost i potreba za većim računalnim resursima mogu predstavljati prepreku za korisnike bez tehničkog znanja. Zbog svoje jednostavnosti i lakše implementacije, model višestruke linearne regresije je najsvrsishodniji model za praktičnu primjenu u školama, osobito u uvjetima kada se traže rješenja koja su jednostavna za razumijevanje i primjenu bez potrebe za naprednim tehničkim resursima.
- Provedena je usporedba stvarne i proračunske potrošnje toplinske energije u predmetnim zgradama. Analiza je ukazala na značajna odstupanja između stvarne i proračunske potrošnje toplinske energije s prosječnim energetske jazom od čak 71 % što je u skladu s prethodnim istraživanjima koja su izvještavala o energetske jaz u obrazovnim zgradama od 60 % do 85 %. Osim toga, utvrđeno je da su financijske razlike nastale radi navedenog energetske jaza godišnje prosječno oko 2000 € većih troškova od predviđenih za toplinsku energiju za grijanje po školi. Analiziran je i uzrok pojave energetske jaza te je utvrđeno da što se tiče vrste škole, osnovne i srednje škole pokazuju slične prosječne vrijednosti energetske jaza (71,53 % i 72,93

%), no deskriptivnom analizom podataka utvrđeno je da osnovne škole imaju širi raspon i veću varijabilnost u podacima. Osim toga, analizom vrste grijanja primijećeno je da su vrijednosti energetske cijene za daljinsko grijanje znatno više i varijabilnije u odnosu na plinsko grijanje. Odnosno, za daljinsko grijanje energetska cijena iznosi čak 100,65 %, a za plinsko grijanje 64,40 %. Nadalje, utvrđeno je da je 66 od ukupno 94 analiziranih škola (70 %) imalo energetska cijena veća od 30 %, a velik broj tih zgrada odnosno 45 od ukupno 66 (68,2 %) izgrađen je prije 1980. godine, prije sustavne implementacije zakonodavstva o toplinskoj izolaciji zgrada.

- Razvijen je sustav procjene stanja školskih zgrada pri čemu je prvo provedena procjena stanja na razini elemenata, a zatim na razini cijele zgrade. Model na razini elemenata razvijen je u MS Excel-u te su dobivene ocjene na razini elemenata korištene za razvoj modela ocjene za cijelu zgradu. Rezultati provedene deskriptivne statističke analize starosti i materijala pojedinih elemenata sugeriraju da, iako su neki dijelovi školskih zgrada u dobrom stanju, drugi su značajno oštećeni i zahtijevaju hitan popravak ili zamjenu. Rezultati su također otkrili značajna odstupanja u stanju komponenti, osobito u elementima kao što su prozori i krovovi, koji su često premašili svoju očekivanu životnu dob što sugerira sistemski problem u praksama održavanja ili raspodjeli financijskih sredstava. Za ocjenu na razini zgrade razvijeni su modeli koristeći neuronske mreže te algoritam nasumične šume. Rezultati su pokazali visoku točnost oba razvijena modela uz prednost točnosti prema neuronskim mrežama. Ocjene stanja među školama, pri čemu značajan broj spada u niže kategorije, naglašavaju hitnu potrebu za ciljanim intervencijama.
- Provedena je i validacija razvijenih modela procjene potrošnje energije, energenata i vode i sustava procjene stanja na posebnom uzorku za validaciju. Pri tome se ova validacija ne odnosi na one prethodno spomenute po poglavljima nego je korišten uzorak škola izvan Osječko-baranjske županije. Korišteno je ukupno 40 škola pri čemu je 20 iz kontinentalne Hrvatske, a 20 iz primorske da bi se utvrdilo jesu li razvijeni modeli i sustav primjenjivi i izvan granica županije. Za predviđanje potrošnje električne energije na navedenom uzorku višestruka linearna regresija istaknula se kao najpouzdaniji model. Za procjenu godišnje potrošnje vode neuronske mreže dale su bolje rezultate, dok se višestruka linearna regresija pokazala kao bolji izbor za procjenu mjesečne potrošnje vode. Vezano uz toplinsku energiju, nisu postignuti dobri rezultati koristeći navedeni uzorak te je utvrđeno da razvijeni modeli procjene potrošnje toplinske energije imaju prostorno ograničenje, odnosno nisu primjenjivi diljem Republike Hrvatske. Za ove modele je iz tog razloga korišten drugi uzorak škola iz istočne Hrvatske gdje se višestruka linearna regresija pokazala najboljim modelom. Za procjenu stanja zgrada oba su modela postigla vrlo visoke performanse, s blagom prednošću za neuronske mreže, no utvrđuje se da oba modela imaju primjenu u procjeni stanja.

- Na temelju navedenog utvrđuje se da jedino model procjene potrošnje toplinske energije ima prostorno ograničenje na istočnu Hrvatsku, dok ostali razvijeni modeli i sustav dokazano testiranjem na skupu validacije, daju dobre rezultate za škole diljem Republike Hrvatske u svim njezinim županijama.

Prednost svih razvijenih modela i sustava je što se temelje na malom broju neovisnih varijabli koje su jednostavno mjerljive i relativno lako dostupne.

8.2. Praktične smjernice za upravljanje imovinom u smislu energetske učinkovitosti i održivosti školskih zgrada

Učinkovito upravljanje školskim zgradama ključno je za osiguranje sigurnog, zdravog i energetski učinkovitog okruženja koje podržava kvalitetu obrazovanja. Praktične smjernice za upravljanje školskim zgradama obuhvaćaju različite aspekte, od redovitog održavanja i praćenja performansi do implementacije dugoročnih strategija za poboljšanje njihove energetske učinkovitosti i funkcionalnosti.

Preporučuje se provoditi sustavne i periodične inspekcije zgrada kako bi se pravovremeno identificirala i sanirala oštećenja konstrukcije, problemi s instalacijama i drugi potencijalni sigurnosni rizici. U tom kontekstu, preporučuje se razviti godišnje i višegodišnje planove održavanja koji uključuju preventivno održavanje, sanaciju manjih oštećenja i planiranje većih renovacija te uključiti prioritetne mjere održavanja za ključne sustave, poput grijanja, ventilacije, klimatizacije, električnih instalacija i vodovodnih sustava.

Preporučuje se ulagati u suvremene tehnologije, poput LED rasvjete, energetski učinkovitih HVAC sustava, solarnih panela i sustava automatizacije zgrada te osigurati adekvatnu toplinsku izolaciju vanjskih zidova, krovova i podova kako bi se smanjili gubici energije. Ako je moguće postaviti senzore i sustave za praćenje potrošnje energije i vode u realnom vremenu te analizirati prikupljene podatke kako bi se identificirali obrasci potrošnje i neučinkovitosti te poduzele odgovarajuće korektivne mjere.

Preporučuje se osigurati dovoljno sredstava za održavanje zgrada kroz proračune obrazovnih ustanova ili putem specifičnih programa financiranja te razmotriti mogućnosti korištenja fondova Europske unije i drugih izvora financiranja za projekte energetske obnove.

Preporučuje se osigurati aktivno uključivanje korisnika školskih zgrada (učenika, nastavnika i roditelja) u identifikaciju potreba i prioriteta za unaprjeđenje zgrada te organizirati edukativne kampanje za korisnike zgrada kako bi se potaknula odgovorna upotreba resursa i održivo ponašanje.

8.3. Smjernice za daljnja istraživanja

Prikazani rezultati u okviru ovog doktorskog rada, prednosti i nedostaci razvijenih modela i sustava te doneseni zaključci predstavljaju čvrstu osnovu za daljnja istraživanja i unapređenja. Slijedom toga, predlažu se sljedeće smjernice za budući rad:

- Razvijeni modeli i sustav procjene stanja trebaju se testirati na različitim tipovima javnih zgrada, kao što su zdravstvene ustanove, sportske dvorane, kulturni objekti (knjižnice, muzeji) i administrativne zgrade. Ova ispitivanja omogućila bi procjenu njihove primjenjivosti na širi spektar objekata i identificirala eventualne prilagodbe potrebne za specifične zahtjeve svakog tipa zgrade.
- S obzirom na slične karakteristike, standarde gradnje i vremenske periode izgradnje u zemljama regije (npr. Slovenija, Srbija, Bosna i Hercegovina, Crna Gora, Mađarska), preporučuje se testiranje modela i sustava u ovom geografskom području što bi omogućilo usporedbu rezultata i prilagodbu modela specifičnostima pojedinih država.
- Preporučuje se proširivanje modela procjene potrošnje toplinske energije kako bi se poboljšala njegova primjenjivost odnosno ako je moguće uklonilo prostorno ograničenje na istočnu Hrvatsku.
- Na temelju rezultata testiranja i primjene modela, preporučuje se izrada edukativnih materijala i smjernica za upravitelje zgrada i donositelje odluka što bi omogućilo širu primjenu modela u praksi te potaknulo osnaživanje kapaciteta za upravljanje energetsom učinkovitošću u javnom sektoru.

POPIS LITERATURE

1. R. Walden, *Schools for the Future. Design Proposals from Architectural Psychology*. 2009, Göttingen, Njemačka: Hogrefe & Huber Pub.
2. H. Clark, *Building Education: The Role of the Physical Environment in Enhancing Teaching and Research. Issues in Practice*. 2002, London, Ujedinjeno Kraljevstvo: ERIC. 49.
3. L. Baker, H. Bernstein, *The impact of school buildings on student health and performance, A Call for Research* (2012),
4. S. Walbe Ornstein, N. Saraiva Moreira, R. Ono, A.J. Limongi Franca, R.A. Nogueira, *Improving the quality of school facilities through building performance assessment: Educational reform and school building quality in São Paulo, Brazil*, *Journal of Educational Administration* (2009), **47**(3) p. 350-367 <https://doi.org/10.1108/09578230910955782>
5. A. Eweda, T. Zayed, S. Alkass, *Space-based condition assessment model for buildings: Case study of educational buildings*, *Journal of Performance of Constructed Facilities* (2015), **29**(1) p. 04014032 [https://doi.org/10.1061/\(ASCE\)CF.1943-5509.0000481](https://doi.org/10.1061/(ASCE)CF.1943-5509.0000481)
6. M. Katafygiotou, D.K. Serghides, *Analysis of structural elements and energy consumption of school building stock in Cyprus: Energy simulations and upgrade scenarios of a typical school*, *Energy and Buildings* (2014), **72** p. 8-16 <https://doi.org/10.1016/j.enbuild.2013.12.024>
7. A.M. Omer, *Energy, environment and sustainable development*, *Renewable and Sustainable Energy Reviews* (2008), **12**(9) p. 2265-2300 <https://doi.org/10.1016/j.rser.2007.05.001>
8. B. Girod, D.P. van Vuuren, E.G. Hertwich, *Climate policy through changing consumption choices: options and obstacles for reducing greenhouse gas emissions*, *Global Environmental Change* (2014), **25** p. 5-15 <https://doi.org/10.1016/j.gloenvcha.2014.01.004>
9. L.B. Cole, *The Teaching Green School Building: Exploring the Contributions of School Design to Informal Environmental Education*, in *Architecture and Natural Resources and Environment*. 2013, University of Michigan: Michigan, SAD.
10. D. Österreicher, *A methodology for integrated refurbishment actions in school buildings*, *Buildings* (2018), **8**(3) p. 42 <https://doi.org/10.3390/buildings8030042>
11. European Commission. *Energy Performance of Buildings Directive*. 2024; Dostupno na: https://energy.ec.europa.eu/topics/energy-efficiency/energy-efficient-buildings/energy-performance-buildings-directive_en.
12. European Commission. *Public Buildings*. 2024; Dostupno na: https://energy.ec.europa.eu/topics/energy-efficiency/energy-efficiency-targets-directive-and-rules/public-buildings_en.
13. Ministarstvo prostornog uređenja graditeljstva i državne imovine Republike Hrvatske, *Dugoročna strategija obnove nacionalnog fonda zgrada do 2050. godine*. 2020.
14. M.S. Gerald, E. Ghisi, *Building-level and stock-level in contrast: A literature review of the energy performance of buildings during the operational stage*, *Energy and Buildings* (2020), **211** p. 109810 <https://doi.org/10.1016/j.enbuild.2020.109810>
15. P. Vassallo, *Analysing the "performance gap" between energy performance certificates and actual energy consumption of non-residential buildings in Malta*, in *Institute for Sustainable Energy*. 2020, University of Malta: Marsaxlokk, Malta.
16. R. Børke, *Energy efficiency in non-residential buildings: Motivation, barriers and strategies*, in *Program for industriell økologi*. 2006, NTNU: Norwegian University of Science and Technology: Trondheim, Norway.
17. A. Boretti, L. Rosa, *Reassessing the projections of the world water development report*, *NPJ Clean Water* (2019), **2**(1) p. 15 <https://doi.org/10.1038/s41545-019-0039-9>
18. Croatian Bureau of Statistics. *Volume of water distributed from public water supply system*. 2024; Dostupno na: https://web.dzs.hr/PXWeb/Selection.aspx?px_path=Okolis_Statistika%20voda_Sakupljanj

-
- [e%20prociscavanje%20i%20distribucija%20voda&px_tableid=SV13.px&px_language=hr&px_db=Okolis&rxid=1e791ae6-e87d-40e6-9f2f-990676ceac17.](#)
19. A.A. Al-Shargabi, A. Almhafdy, D.M. Ibrahim, M. Alghieth, F. Chiclana, *Buildings' energy consumption prediction models based on buildings' characteristics: Research trends, taxonomy, and performance measures*, Journal of Building Engineering (2022), **54** p. 104577 <https://doi.org/10.1016/j.jobbe.2022.104577>
 20. L. Yang, H. Yan, J.C. Lam, *Thermal comfort and building energy consumption implications—a review*, Applied Energy (2014), **115** p. 164-173 <https://doi.org/10.1016/j.apenergy.2013.10.062>
 21. Službeni list SFRJ br. 35/70., Pravilnik o tehničkim mjerama i uvjetima za toplinsku zaštitu zgrada. 1970.
 22. R.C. Hunter, *The Public School Infrastructure Problem: Deteriorating Buildings and Deferred Maintenance*, School Business Affairs (2009), **75**(2) p. 10-12
 23. J.H. Lee, H.M. Aktan, A study of building deterioration, in Infrastructure Condition Assessment: Art, Science, and Practice, M. Saito, Editor. 1997, ASCE: Boston, Massachusetts, SAD. p. 1-10.
 24. P.W. Karanja, Current State of Practice For Condition Assessment Methods and The Facility Condition Index as a Measure. 2017, University of North Carolina: Charlotte, SAD.
 25. A. Straub, *Using a condition-dependent approach to maintenance to control costs and performances*, Journal of Facilities Management (2002), **1**(4) p. 380-395 <https://doi.org/10.1108/14725960310808079>
 26. L. Chouinard, G. Andersen, V. Torrey III, *Ranking models used for condition assessment of civil infrastructure systems*, Journal of infrastructure systems (1996), **2**(1) p. 23-29 [https://doi.org/10.1061/\(ASCE\)1076-0342\(1996\)2:1\(23\)](https://doi.org/10.1061/(ASCE)1076-0342(1996)2:1(23))
 27. E. Teicholz, *Computer-aided facilities management and facility conditions assessment software*, Facilities (1995), **13**(6) p. 16-19 [10.1108/02632779510085177](https://doi.org/10.1108/02632779510085177)
 28. A.W. Sadek, A. Kvasnak, J. Segale, *Integrated infrastructure management systems: Small urban area's experience*, Journal of Infrastructure Systems (2003), **9**(3) p. 98-106 [https://doi.org/10.1061/\(ASCE\)1076-0342\(2003\)9:3\(9\)](https://doi.org/10.1061/(ASCE)1076-0342(2003)9:3(9))
 29. N. Strong. Making the Case for Facility Condition Assessment: The Three W's. U: CEFPI 2004. 2004. Burgess Carter, SAD. <https://doi.org/10.1051/mateconf/201925803003>
 30. J.M. Rugless, *Condition assessment surveys*, AIPE FACILITIES (1993), **20** p. 11-11
 31. M.M. Fagan, D.M. Kirkwood, P. FHFI. Facility condition assessments: more than just making a list. U: Proceedings of 34th Annual Conference and Technical Exhibition. 1997. San Antonio, Texas: American Society for Healthcare Engineering
 32. H.H. Kaiser, J.S. Davis, A Foundation To Uphold: A Study of Facilities Conditions at US Colleges and Universities. 1996, Alexandria, SAD: ERIC.
 33. B.T. Lewis, R.P. Payant, *Facility Inspection Field Manual: A complete condition assessment guide*. 2001, McGraw-Hill.
 34. G. Abbott, J. McDuling, S. Parsons, J. Schoeman. Building condition assessment: a performance evaluation tool towards sustainable asset management. U: CIB World Building Congress 2007. 2007. Cape Town, Afrika: CIB
 35. International Organization for Standardization, ISO 15686-1:2011. 2011.
 36. T. Ingvaldsen, Byggskaedemfanget i Norge-Prosjektrapport 17, in Sintef Byggforsk. Oslo. 2008.
 37. D.S. Watt, *Building pathology: Principles and practice*. 2009, Hoboken, New Jersey, SAD: John Wiley & Sons.
 38. S.N.F. Zuraidi, M.A.A. Rahman, Z.A. Akasah. Elements of building defect: A review of the recent literature. U: 13th Universiti Malaysia Terengganu International Annual Symposium on Sustainability Science and Management: Science and Technology for Sustainable Livelihood. 2016. Terengganu, Malezija: Diterbitkan oleh
 39. A.A. Elhakeem, An asset management framework for educational buildings with life-cycle cost analysis. 2005, University of Waterloo Waterloo, Ontario, Kanada.
-

40. L. Robjant, P. Clark, M. Marti, R. Freese, A. Johnson, C. County, *Asset Management Guide for Local Agencies*. 2019, Minnesota. Department of Transportation. Office of Research & Innovation.
41. A.G. Mohamed, M. Marzouk, *Building condition assessment using artificial neural network and structural equations*, *Expert Systems with Applications* (2021), **186** p. 115743 <https://doi.org/10.1016/j.eswa.2021.11574>
42. A.M. Hassan, K. Adel, A. Elhakeem, M.I. Elmasry, *Condition Prediction for Existing Educational Facilities Using Artificial Neural Networks and Regression Analysis*, *Buildings* (2022), **12**(10) p. 1520 <https://doi.org/10.3390/buildings12101520>
43. D.R. Uzarski, M.N. Grussing, J.B. Clayton, *Knowledge-based condition survey inspection concepts*, *Journal of infrastructure systems* (2007), **13**(1) p. 72-79 [https://doi.org/10.1061/\(ASCE\)1076-0342\(2007\)13:1\(72\)](https://doi.org/10.1061/(ASCE)1076-0342(2007)13:1(72))
44. National Centre for Education Statistics, *Facilities Information Management: A Guide for State and Local Education*. 2003.
45. J.B. Clayton, *Condition Assessment in Facility Asset Management. Technology for Facility Managers: The Impact of Cutting-Edge Technology on Facility Management*. 2012, Houston, SAD: IFMA. 137-169.
46. S. Singh Ahluwalia, *A framework for efficient condition assessment of the building infrastructure*. 2008, University of Waterloo: Waterloo, Ontario, Canada.
47. M. Shahin, 20 years experience in the PAVER pavement management system: development and implementation, in *Pavement Management Implementation*, FB Holt and W. Gramling, Editors. 1991, ASTM International.
48. M.Y. Shahin, *Development of the US Army Railroad Track Maintenance Management System (RAILER)*. 1986, Construction Engineering Research Laboratory.
49. F.F. Council, *Budgeting for Facilities Maintenance and Repair Activities*. 1996, National Academies.
50. D.M. Bailey, D.E. Brotherson, W. Tobiasson, A. Knehans, *ROOFER: An engineered management system (EMS) for bituminous built-up roofs*. 1989.
51. D.R. Uzarski, L.A. Burley, *Assessing building condition by the use of condition indexes. Infrastructure condition assessment: art, science, and practice*. 1997, Virginia, SAD: ASCE. 365-374.
52. D. Uzarski, D.K. Hicks, J. Zahorak, *Building and building component condition and capability metrics*, in *Applications of Advanced Technologies in Transportation* (2002), K. Wang, et al., Editors. 2002, ASCE: Virginia, SAD. p. 441-448.
53. E. Brandt, M. Rasmussen, *Assessment of building conditions*, *Energy and buildings* (2002), **34**(2) p. 121-125 [https://doi.org/10.1016/S0378-7788\(01\)00102-5](https://doi.org/10.1016/S0378-7788(01)00102-5)
54. A. Straub, *Dutch standard for condition assessment of buildings*, *Structural Survey* (2009), **27**(1) p. 23-35 <https://doi.org/10.1108/02630800910941665>
55. J. António Costa Branco de Oliveira Pedro, J. Ângelo Vasconcelos de Paiva, A. José Dâmaso Santos Matos Vilhena, *Portuguese method for building condition assessment*, *Structural Survey* (2008), **26**(4) p. 322-335 <https://doi.org/10.1108/02630800810906566>
56. D. Ho, K. Chau, Y. Yau, A. Cheung, S. Wong, *Comparative study of building performance assessment schemes in Hong Kong*, *Hong Kong Surveyor*, (2005), **16**(1) p. 47-58
57. F. Faqih, T. Zayed, *A comparative review of building component rating systems*, *Journal of Building Engineering* (2021), **33** p. 101588 <https://doi.org/10.1016/j.jobbe.2020.101588>
58. M. Chew, N. De Silva, *Maintainability problems of wet areas in high-rise residential buildings*, *Building Research and Information* (2003), **31**(1) p. 60-69
59. J. Kempton, S. Nichol, C. Anumba, J. Dickens, *Surveyor variability in large-scale house condition surveys*, *Structural Survey* (2001), **19**(4) p. 156-162 <https://doi.org/10.1108/02630800110406658>

60. D. Scott, C.J. ANUMBA, *An intelligent approach to the engineering management of subsidence cases*, Engineering, Construction and Architectural Management (1996), **3**(3) p. 233-248 <https://doi.org/10.1108/eb021033>
61. R.M. Hogarth, *Accounting for decisions and decisions for accounting*, Accounting, Organizations and Society (1993), **18**(5) p. 407-424 [https://doi.org/10.1016/0361-3682\(93\)90039-9](https://doi.org/10.1016/0361-3682(93)90039-9)
62. P.D. Thompson, E.P. Small, M. Johnson, A.R. Marshall, *The Pontis bridge management system*, Structural engineering international (1998), **8**(4) p. 303-308 <https://doi.org/10.2749/101686698780488758>
63. K. Golabi, R. Shepard, *Pontis: A system for maintenance optimization and improvement of US bridge networks*, Interfaces (1997), **27**(1) p. 71-88 <https://doi.org/10.1287/inte.27.1.71>
64. L. Greimann, J. Stecker, K. Rens. Condition assessment of navigation lock and dam structures. U: 1996 Semisesquicentennial Transportation Conference Proceedings. Iowa State University and Iowa Department of Transportation. 1996. Iowa, SAD: Center for Transportation Research and Education
65. Z. Lounis, M.A. Lacasse, D.J. Vanier, B.R. Kyle, Towards standardization of service life prediction of roofing membranes, in ASTM Special Technical Publication. 1999, p. 3-18.
66. Department for Education and Skills, Assessment Management Plans - Condition Assessments, Section 3a: Getting into the Condition. 2003.
67. A. Elhakeem, T. Hegazy. Towards a visual guidance system for condition assessment of the building infrastructure. U: Proceedings of 1st CSCE Specialty Conference on Infrastructure Technologies, Management, and Policies. 2005. Toronto, Kanada: CSCE
68. D.C.-W. Ho, K.-W. Chau, A.K.-C. Cheung, Y. Yau, S.-K. Wong, H.-F. Leung, S.S.-Y. Lau, W.-S. Wong, *A survey of the health and safety conditions of apartment buildings in Hong Kong*, Building and Environment (2008), **43**(5) p. 764-775 <https://doi.org/10.1016/j.buildenv.2007.01.035>
69. N. Salim, N. Zahari, *Developing integrated building indicator system (IBIS)(a method of formulating the building condition rating)*, Procedia Engineering (2011), **20** p. 256-261 <https://doi.org/10.1016/j.proeng.2011.11.163>
70. A. Eweda, An integrated condition assessment model for educational buildings using BIM. 2012, Concordia University: Montreal, Kanada.
71. W. Wilson, Housing health and safety rating system (HHSRS). 2008, Standard Note SN/SP/1917 3. Social Policy Section, House of Commons Library.
72. E. Piaia, F. Maietti, R. Di Giulio, O. Schippers-Trifan, A. Van Delft, S. Bruinenberg, R. Olivadese, *BIM-based cultural heritage asset management tool. Innovative solution to orient the preservation and valorization of historic buildings*, International Journal of Architectural Heritage (2021), **15**(6) p. 897-920 <https://doi.org/10.1080/15583058.2020.1734686>
73. T.J. Pitt, *Data requirements for the prioritization of predictive building maintenance*, Facilities (1997), **15**(3/4) p. 97-104 <https://doi.org/10.1108/02632779710160612>
74. R. Langevine, M. Allouche, S. AbouRizk. Decision support tool for the maintenance management of buildings. U: Joint international conference on computing and decision making in civil and building engineering. 2006. Montreal, Kanada
75. R. Langevine, A decision support system for the maintenance management of buildings. 2006, University of Alberta: Montreal, Kanada.
76. R. Kuijper, D. Bezemer, J. Bakker, D. Frangopol, K. van Breugel, Standardization of condition assessment methodologies for structures, in Life-Cycle of Civil Engineering Systems, R. Caspeele, L. Taerwe, and D. Frangopol, Editors. 2017, CRC Press: Boca Raton, Florida, SAD. p. 669-674.
77. M.C. Dejaco, F. RE CECCONI, S. Maltese. A rating system for building condition ranking. U: Proceedings of CIB Facilities Management Conference. 2014. Kopenhagen, Danska: Polteknisk Forlag

78. M.C. Dejaco, F.R. Cecconi, S. Maltese, *Key performance indicators for building condition assessment*, Journal of Building Engineering (2017), **9** p. 17-28 <https://doi.org/10.1016/j.jobe.2016.11.004>
79. M.N. Grussing, L.Y. Liu, D.R. Uzarski, K. El-Rayes, N. El-Gohary, *Discrete Markov approach for building component condition, reliability, and service-life prediction modeling*, Journal of Performance of Constructed Facilities (2016), **30**(5) p. 04016015 [https://doi.org/10.1061/\(ASCE\)CF.1943-5509.0000865](https://doi.org/10.1061/(ASCE)CF.1943-5509.0000865)
80. S.M. Noor, C.S. Mei, I.S. Ibrahim, N.N. Sarbini, M.H. Osman, N.A. Khiyon, *Heritage building condition assessment: a case study from Johor Bahru, Malaysia*, IOP Conference Series: Earth and Environmental Science (2019), **220**(1) p. 012024 10.1088/1755-1315/220/1/012024
81. V. Lupășteanu, R. Lupășteanu, C. Chingălată, *Condition assessment of buildings in Romania: A proposed method and case study*, Journal of Building Engineering (2022), **47** p. 103814 <https://doi.org/10.1016/j.jobe.2021.103814>
82. H. Ahmed, K. Mostafa, T. Hegazy, *Utilizing different artificial intelligence techniques for efficient condition assessment of building components*, Canadian Journal of Civil Engineering (2023), **51**(4) p. 379-389 <https://doi.org/10.1139/cjce-2023-0046>
83. R. Buoń, A. Czarnigowska, *Decision support method for optimal modernization of residential buildings*, Archives of Civil Engineering (2024), **70**(1) p. 219-237 <https://doi.org/10.24425/ace.2024.148908>
84. F. Faqih, T. Zayed, *Defect-based building condition assessment*, Building and Environment (2021), **191** p. 107575 <https://doi.org/10.1016/j.buildenv.2020.107575>
85. A. Che-Ani, A. Ali, M.M. Tahir, N. Abdullah, N. Tawil. The development of a condition survey protocol (CSP) 1 matrix for visual building inspection. U: Cobra 2010. 2010. Pariz, Francuska: RICS
86. N. Hamzah, M. Mahli, A. Che Ani, M. Tahir, N. Abdullah, N. Tawil, *The development of smart school condition assessment based on condition survey protocol (CSP) 1 matrix: A literature review*, Science, Engineering and Technology (2010), p. 620-625
87. M. Mahli, A. Che-Ani, M. Abd-Razak, N. Tawil, H. Yahaya, *School age and building defects: Analysis using condition survey protocol (CSP) 1 matrix*, International Journal of Civil, Architectural, Structural and Construction Engineering (2012), **6**(7) p. 56-58
88. A. Eweda, T. Zayed, S. Alkass. An integrated condition assessment model for buildings. U: Construction Research Congress 2010: Innovation for Reshaping Construction Practice. 2010. Alberta, Kanada: American Society of Civil Engineers
89. A. Eweda, A. Al-Sakkaf, T. Zayed, S. Alkass, *Condition assessment model of building indoor environment: a case study on educational buildings*, International Journal of Building Pathology and Adaptation (2021), **41**(4) p. 767-788 <https://doi.org/10.1108/IJBPA-03-2021-0036>
90. A. ElSamadony, O. Hossny, A. ElHakeem, D. Hussein, *An asset management system for maintenance and repair of educational buildings*, International Journal of Scientific & Engineering Research (2013), **4**(6) p. 2053-2064
91. M. Marzouk, E. Awad, *Establishing multi-level performance condition indices for public schools maintenance program using AHP and fuzzy logic*, Studies in Informatics and Control (2016), **25**(3) p. 343-352 10.24846/v25i3y201608
92. A.-M. Sadick, M.H. Issa, *Assessing physical conditions of indoor space enclosing elements in schools in relation to their indoor environmental quality*, Journal of Building Engineering (2018), **20** p. 520-530 <https://doi.org/10.1016/j.jobe.2018.08.018>
93. S. Linggar, A. Aminullah, A. Triwiyono. Analysis of building and its components condition assessment case study of dormitory buildings. U: International Conference on Sustainable Civil Engineering Structures and Construction Materials (SCESCM 2018). 2019. Yogyakarta, Indonesia: EDP Sciences

94. K. Kejeh, I.L. Nwaogazie, S. Samuel, *Maintenance-State Assessment Model for Building Maintenance Forecasting*, Archives of Current Research International (2022), **22**(7) p. 40-54 [10.9734/acri/2022/v22i7538](https://doi.org/10.9734/acri/2022/v22i7538)
95. K.T. Štok, D. Car-Pušić, S. Marenjak, *Elementary School Buildings Condition Assessment: Case of Primorje-Gorski Kotar County (Croatia)*, Advances in Civil and Architectural Engineering (2023), **14**(26) p. 95-117 <https://doi.org/10.13167/2023.26.7>
96. M. Chew, N. De Silva, *Maintainability problems of wet areas in high-rise residential buildings*, Build. Res. Inf. (2003), **31**(1) p. 60-69
97. J. Kempton, S. Nichol, C. Anumba, J. Dickens, *Surveyor variability in large-scale house condition surveys*, Struct. Surv. (2001), **19**(4) p. 156-162 <https://doi.org/10.1108/02630800110406658>
98. F. Faqih, T. Zayed, *A comparative review of building component rating systems*, J. Build. Eng. (2021), **33** p. 101588 <https://doi.org/10.1016/j.jobbe.2020.101588>
99. S.K. Alghoul, A.O. Gweshia, A.M. Naas, *The effect of electricity price on saving energy transmitted from external building walls*, Energy Research Journal (2016), **7**(1) p. 1-9 <https://doi.org/10.3844/erjsp.2016.1.9>
100. X. Cao, X. Dai, J. Liu, *Building energy-consumption status worldwide and the state-of-the-art technologies for zero-energy buildings during the past decade*, Energy and Buildings (2016), **128** p. 198-213 <https://doi.org/10.1016/j.enbuild.2016.06.089>
101. D. D'Agostino, B. Cuniberti, P. Bertoldi, *Energy consumption and efficiency technology measures in European non-residential buildings*, Energy and Buildings (2017), **153** p. 72-86 <https://doi.org/10.1016/j.enbuild.2017.07.062>
102. S.P. Corgnati, V. Corrado, M. Filippi, *A method for heating consumption assessment in existing buildings: A field survey concerning 120 Italian schools*, Energy and Buildings (2008), **40**(5) p. 801-809 <https://doi.org/10.1016/j.enbuild.2007.05.011>
103. L.D. Pereira, D. Raimondo, S.P. Corgnati, M.G. Da Silva, *Energy consumption in schools—A review paper*, Renewable and Sustainable Energy Reviews (2014), **40** p. 911-922 <https://doi.org/10.1016/j.rser.2014.08.010>
104. M.W. Ahmad, M. Mourshed, Y. Rezgui, *Trees vs Neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption*, Energy and Buildings (2017), **147** p. 77-89 <https://doi.org/10.1016/j.enbuild.2017.04.038>
105. D. Dumciuvienė, A. Cibinskiene, M. Melenhorst, J. Novak, *Determinants of sustainable energy consumption in schools*, Proceedings (2018), **2**(22) p. 1382 <https://doi.org/10.3390/proceedings2221382>
106. L.N. Antunes, E. Ghisi, *Water and energy consumption in schools: case studies in Brazil*, Environment, development and sustainability (2020), **22** p. 4225-4249 <https://doi.org/10.1007/s10668-019-00380-x>
107. D. Godoy-Shimizu, P. Armitage, K. Steemers, T. Chenvidyakarn, *Using Display Energy Certificates to quantify schools' energy consumption*, Building Research & Information (2011), **39**(6) p. 535-552 <https://doi.org/10.1080/09613218.2011.628457>
108. M.M. Ouf, M.H. Issa, *Energy consumption analysis of school buildings in Manitoba, Canada*, International Journal of Sustainable Built Environment (2017), **6**(2) p. 359-371 <https://doi.org/10.1016/j.ijsbe.2017.05.003>
109. L. Pérez-Lombard, J. Ortiz, C. Pout, *A review on buildings energy consumption information*, Energy and Buildings (2008), **40**(3) p. 394-398 <https://doi.org/10.1016/j.enbuild.2007.03.007>
110. Y.V. Perez, I.G. Capeluto, *Climatic considerations in school building design in the hot-humid climate for reducing energy consumption*, Applied Energy (2009), **86**(3) p. 340-348 <https://doi.org/10.1016/j.apenergy.2008.05.007>
111. C. Bhowmik, S. Bhowmik, A. Ray, K.M. Pandey, *Optimal green energy planning for sustainable development: A review*, Renewable and Sustainable Energy Reviews (2017), **71** p. 796-813 <https://doi.org/10.1016/j.rser.2016.12.10>

112. L. Chen, Z. Chen, Y. Zhang, Y. Liu, A.I. Osman, M. Farghali, J. Hua, A. Al-Fatesh, I. Ihara, D.W. Rooney, *Artificial intelligence-based solutions for climate change: a review*, Environmental Chemistry Letters (2023), **21**(5) p. 2525-2557 <https://doi.org/10.1007/s10311-023-01617-y>
113. A. Mohammed, A. Alshibani, O. Alshamrani, M. Hassanain, *A regression-based model for estimating the energy consumption of school facilities in Saudi Arabia*, Energy and Buildings (2021), **237** p. 110809 <https://doi.org/10.1016/j.enbuild.2021.110809>
114. N. Soares, J. Bastos, L.D. Pereira, A. Soares, A. Amaral, E. Asadi, E. Rodrigues, F. Lamas, H. Monteiro, M. Lopes, *A review on current advances in the energy and environmental performance of buildings towards a more sustainable built environment*, Renewable and Sustainable Energy Reviews (2017), **77** p. 845-860 <https://doi.org/10.1016/j.rser.2017.04.027>
115. Y. Ding, H. Brattebø, N. Nord, *A systematic approach for data analysis and prediction methods for annual energy profiles: an example for school buildings in Norway*, Energy and Buildings (2021), **247** p. 111160 <https://doi.org/10.1016/j.enbuild.2021.111160>
116. C. Li, Z. Ding, D. Zhao, J. Yi, G. Zhang, *Building energy consumption prediction: An extreme deep learning approach*, Energies (2017), **10**(10) p. 1525 <https://doi.org/10.3390/en10101525>
117. R. Olu-Ajayi, H. Alaka, H. Owolabi, L. Akanbi, S. Ganiyu, *Data-driven tools for building energy consumption prediction: A review*, Energies (2023), **16**(6) p. 2574 <https://doi.org/10.3390/en16062574>
118. V. Butala, P. Novak, *Energy consumption and potential energy savings in old school buildings*, Energy and buildings (1999), **29**(3) p. 241-246 [https://doi.org/10.1016/S0378-7788\(98\)00062-0](https://doi.org/10.1016/S0378-7788(98)00062-0)
119. T.-W. Kim, K.-G. Lee, W.-H. Hong, *Energy consumption characteristics of the elementary schools in South Korea*, Energy and Buildings (2012), **54** p. 480-489 <https://doi.org/10.1016/j.enbuild.2012.07.015>
120. J.C. Wang, *Energy consumption in elementary and high schools in Taiwan*, Journal of Cleaner Production (2019), **227** p. 1107-1116 <https://doi.org/10.1016/j.jclepro.2019.04.254>
121. W. Chung, I.M. Yeung, *A study of energy consumption of secondary school buildings in Hong Kong*, Energy and Buildings (2020), **226** p. 110388 <https://doi.org/10.1016/j.enbuild.2020.110388>
122. D. Daly, J. Roth, G. Kokogiannakis, C. McDowell, M. Tibbs, P. Cooper, *Energy consumption in Australian primary schools: Influences and metrics*, Energy and Buildings (2022), **277** p. 112549 <https://doi.org/10.1016/j.enbuild.2022.112549>
123. E. Beusker, C. Stoy, S.N. Pollalis, *Estimation model and benchmarks for heating energy consumption of schools and sport facilities in Germany*, Building and Environment (2012), **49** p. 324-335 <https://doi.org/10.1016/j.buildenv.2011.08.006>
124. P. Hernandez, K. Burke, J.O. Lewis, *Development of energy performance benchmarks and building energy ratings for non-domestic buildings: An example for Irish primary schools*, Energy and Buildings (2008), **40**(3) p. 249-254 <https://doi.org/10.1016/j.enbuild.2007.02.020>
125. M. Santamouris, G. Mihalakakou, P. Patargias, N. Gaitani, K. Sfakianaki, M. Papaglastra, C. Pavlou, P. Doukas, E. Primikiri, V. Geros, *Using intelligent clustering techniques to classify the energy performance of school buildings*, Energy and Buildings (2007), **39**(1) p. 45-51 <https://doi.org/10.1016/j.enbuild.2006.04.018>
126. S.-M. Hong, G. Paterson, D. Mumovic, P. Steadman, *Improved benchmarking comparability for energy consumption in schools*, Building Research & Information (2014), **42**(1) p. 47-61 <https://doi.org/10.1080/09613218.2013.814746>
127. S. Attia, N. Shadmanfar, F. Ricci, *Developing two benchmark models for nearly zero energy schools*, Applied Energy (2020), **263** p. 114614 <https://doi.org/10.1016/j.apenergy.2020.114614>
128. D. Katić, H. Krstić, S. Marenjak, *Energy performance of school buildings by construction periods in federation of Bosnia and Herzegovina*, Buildings (2021), **11**(2) p. 42 <https://doi.org/10.3390/buildings11020042>

129. N. Jurišević, D. Gordić, N. Lukić, M. Josijević, *Benchmarking heat consumption in educational buildings in the city of Kragujevac (Serbia)*, Energy Efficiency (2018), **11** p. 1023-1039 <https://doi.org/10.1007/s12053-018-9631-y>
130. T. Kim, B. Kang, H. Kim, C. Park, W.-H. Hong, *The study on the Energy Consumption of middle school facilities in Daegu, Korea*, Energy Reports (2019), **5** p. 993-1000 <https://doi.org/10.1016/j.egyr.2019.07.015>
131. C. Jasper, T.-T. Le, J. Bartram, *Water and sanitation in schools: a systematic review of the health and educational outcomes*, International journal of environmental research and public health (2012), **9**(8) p. 2772-2787 10.3390/ijerph9082772
132. C. Cheng, Y. Hong, *Evaluating water utilization in primary schools*, Building and Environment (2004), **39**(7) p. 837-845 <https://doi.org/10.1016/j.buildenv.2004.01.006>
133. Á.-F. Morote, M. Hernández, J. Olcina, A.-M. Rico, *Water consumption and management in schools in the City of Alicante (Southern Spain)(2000–2017): Free water helps promote saving water?*, Water (2020), **12**(4) p. 1052 <https://doi.org/10.3390/w12041052>
134. J.D. Schultt, A. Kalbusch, E. Henning, *Factors influencing water consumption in public schools in Southern Brazil*, Environment, Development and Sustainability (2022), **24**(1) p. 1411-1427 10.1007/s10668-021-01473-2
135. M. Farina, M. Maglionico, M. Pollastri, I. Stojkov, *Water consumptions in public schools*, Procedia Engineering (2011), **9**(21) p. 929-938 10.1016/j.proeng.2011.11.2096
136. R.M. Almeida, N.M. Ramos, M.L. Simões, V.P. de Freitas, *Energy and water consumption variability in school buildings: review and application of clustering techniques*, Journal of Performance of Constructed Facilities (2015), **29**(6) p. 04014165 [https://doi.org/10.1061/\(ASCE\)CF.1943-5509.0000663](https://doi.org/10.1061/(ASCE)CF.1943-5509.0000663)
137. R. Almeida, N. Ramos, M. Simões, V. Freitas. Variability of energy and water consumption of school buildings. U: 2nd Central European Symposium on Building Physics. 2013. Beč, Austrija: Vienna University of Technology - Faculty of Architecture and Regional Planning, Vienna, Austria
138. L.G.C.F. Nunes, A.E.P. Soares, J.K. da Silva, S.R. da Silva, *Rational water use indicators for public schools in Recife, Brazil*, Water Supply (2019), **19**(1) p. 207-215 <https://doi.org/10.2166/ws.2018.068>
139. A. Capozzoli, D. Grassi, F. Causone, *Estimation models of heating energy consumption in schools for local authorities planning*, Energy and Buildings (2015), **105** p. 302-313 <https://doi.org/10.1016/j.enbuild.2015.07.024>
140. A. Alshibani, *Prediction of the energy consumption of school buildings*, Applied Sciences (2020), **10**(17) p. 5885 <https://doi.org/10.3390/app10175885>
141. M. Faiq, K.G. Tan, C.P. Liew, F. Hossain, C.-P. Tso, L.L. Lim, A.Y.K. Wong, Z.M. Shah, *Prediction of energy consumption in campus buildings using long short-term memory*, Alexandria Engineering Journal (2023), **67** p. 65-76 <https://doi.org/10.1016/j.aej.2022.12.015>
142. W. Cao, J. Yu, M. Chao, J. Wang, S. Yang, M. Zhou, M. Wang, *Short-term energy consumption prediction method for educational buildings based on model integration*, Energy (2023), **283** p. 128580 <https://doi.org/10.1016/j.energy.2023.128580>
143. Z.K. Shahid, S. Saguna, C. Åhlund. Forecasting Electricity and District Heating Consumption: A Case Study in Schools in Sweden. U: 2023 IEEE Green Technologies Conference (GreenTech). 2023. Denver, SAD: IEEE.10.1109/GreenTech56823.2023.10173792
144. K. Elhabyb, A. Baina, M. Bellafkih, A.F. Deifalla, *Machine Learning Algorithms for Predicting Energy Consumption in Educational Buildings*, International Journal of Energy Research (2024), **2024**(1) p. 1-19 <https://doi.org/10.1155/2024/6812425>
145. G. Doiphode, H. Najafi. A Machine Learning Based Approach for Energy Consumption Forecasting in K-12 Schools. U: ASME International Mechanical Engineering Congress and Exposition. 2020. Online: American Society of Mechanical Engineers

146. M. Soares Geraldi, M. Vinicius Bavaresco, E. Ghisi. Bayesian network for predicting energy consumption in schools in Florianópolis–Brazil. U: *Building Simulation 2019*. 2019. Rim, Italija: IBPSA
147. K. Run, F. Cévaër, J.-F. Dubé, Preliminary Multiple Linear Regression Model to Predict Hourly Electricity Consumption of School Buildings, in *Future Energy: Challenge, Opportunity, and, Sustainability*, A. Doyle, Editor. 2023, Springer: New York, SAD. p. 119-127.
148. J. Li, S. Song, *Urban water consumption prediction based on CPMBNIP*, *Water Resources Management* (2023), **37**(13) p. 5189-5213 <https://doi.org/10.1007/s11269-023-03601-1>
149. R. Tariq, A. Mohammed, A. Alshibani, M.S. Ramírez-Montoya, *Complex artificial intelligence models for energy sustainability in educational buildings*, *Scientific Reports* (2024), **14**(1) p. 15020 <https://doi.org/10.1038/s41598-024-65727-5>
150. A.P. Almeida, V. Sousa, C.M. Silva, *Methodology for estimating energy and water consumption patterns in university buildings: Case study, Federal University of Roraima (UFRR)*, *Heliyon* (2021), **7**(12) <https://doi.org/10.1016/j.heliyon.2021.e08642>
151. N. Jurišević, D. Gordić, V. Vukašinović, A. Vukićević, *Assessment of predictive models for estimation of water consumption in public preschool buildings*, *Journal of Engineering Research* (2022), **10**(2B) p. 98-111 <https://doi.org/10.36909/jer.10941>
152. K.G. Droutsa, S. Kontoyiannidis, E.G. Dascalaki, C.A. Balaras, *Mapping the energy performance of hellenic residential buildings from EPC (energy performance certificate) data*, *Energy* (2016), **98** p. 284-295 <https://doi.org/10.1016/j.energy.2015.12.137>
153. Buildings Performance Institute Europe (BPIE), *Energy performance certificates across the EU*. 2014.
154. Y. Li, S. Kubicki, A. Guerriero, Y. Rezgui, *Review of building energy performance certification schemes towards future improvement*, *Renewable and Sustainable Energy Reviews* (2019), **113** p. 109244 <https://doi.org/10.1016/j.rser.2019.109244>
155. C.A. Balaras, E.G. Dascalaki, K.G. Droutsa, S. Kontoyiannidis, *Empirical assessment of calculated and actual heating energy use in Hellenic residential buildings*, *Applied Energy* (2016), **164** p. 115-132 <https://doi.org/10.1016/j.apenergy.2015.11.027>
156. D. Palladino, *Energy performance gap of the Italian residential building stock: Parametric energy simulations for theoretical deviation assessment from standard conditions*, *Applied Energy* (2023), **345** p. 121365 <https://doi.org/10.1016/j.apenergy.2023.121365>
157. R. Gupta, A. Kotopouleas, *Magnitude and extent of building fabric thermal performance gap in UK low energy housing*, *Applied Energy* (2018), **222** p. 673-686 <https://doi.org/10.1016/j.apenergy.2018.03.096>
158. B. Hårsman, Z. Daghbashyan, P. Chaudhary, *On the quality and impact of residential energy performance certificates*, *Energy and Buildings* (2016), **133** p. 711-723 <https://doi.org/10.1016/j.enbuild.2016.10.033>
159. A. Mahdavi, C. Berger, H. Amin, E. Ampatzi, R.K. Andersen, E. Azar, V.M. Barthelmes, M. Favero, J. Hahn, D. Khovalyg, *The role of occupants in buildings' energy performance gap: myth or reality?*, *Sustainability* (2021), **13**(6) p. 3146 <https://doi.org/10.3390/su13063146>
160. Z. Zheng, J. Zhou, Z. Jiaqin, Y. Yang, F. Xu, H. Liu, *Review of the building energy performance gap from simulation and building lifecycle perspectives: Magnitude, causes and solutions*, *Developments in the Built Environment* (2024), p. 100345 <https://doi.org/10.1016/j.dibe.2024.100345>
161. P. Hernandez-Cruz, C. Giraldo-Soto, C. Escudero-Revilla, J.M. Hidalgo-Betanzos, I. Flores-Abascal, *Energy efficiency and energy performance gap in centralized social housing buildings of the Basque Country*, *Energy and Buildings* (2023), **298** p. 113534 <https://doi.org/10.1016/j.enbuild.2023.113534>
162. S. Cozza, J. Chambers, A. Brambilla, M.K. Patel, *In search of optimal consumption: A review of causes and solutions to the Energy Performance Gap in residential buildings*, *Energy and Buildings* (2021), **249** p. 111253 <https://doi.org/10.1016/j.enbuild.2021.111253>

163. P. De Wilde, *The gap between predicted and measured energy performance of buildings: A framework for investigation*, Automation in Construction (2014), **41** p. 40-49 <https://doi.org/10.1016/j.autcon.2014.02.009>
164. P.X. Zou, D. Wagle, M. Alam, *Strategies for minimizing building energy performance gaps between the design intend and the reality*, Energy and Buildings (2019), **191** p. 31-41 <https://doi.org/10.1016/j.enbuild.2019.03.013>
165. A.C. Menezes, A. Cripps, D. Bouchlaghem, R. Buswell, *Predicted vs. actual energy performance of non-domestic buildings: Using post-occupancy evaluation data to reduce the performance gap*, Applied Energy (2012), **97** p. 355-364 <https://doi.org/10.1016/j.apenergy.2011.11.075>
166. S. Cozza, J. Chambers, C. Deb, J.-L. Scartezzini, A. Schlüter, M.K. Patel, *Do energy performance certificates allow reliable predictions of actual energy consumption and savings? Learning from the Swiss national database*, Energy and Buildings (2020), **224** p. 110235 <https://doi.org/10.1016/j.enbuild.2020.110235>
167. S. Cozza, J. Chambers, M.K. Patel, *Measuring the thermal energy performance gap of labelled residential buildings in Switzerland*, Energy Policy (2020), **137** p. 111085 <https://doi.org/10.1016/j.enpol.2019.111085>
168. B. Coyne, E. Denny, *Mind the energy performance gap: testing the accuracy of building energy performance certificates in Ireland*, Energy Efficiency (2021), **14**(6) p. 57 [10.1007/s12053-021-09960-1](https://doi.org/10.1007/s12053-021-09960-1)
169. C. Van Dronkelaar, M. Dowson, E. Burman, C. Spataru, D. Mumovic, *A review of the energy performance gap and its underlying causes in non-domestic buildings*, Frontiers in Mechanical Engineering (2016), **1** p. 17 <https://doi.org/10.3389/fmech.2015.00017>
170. D. Katić, H. Krstić, *Potrošnja toplinske energije školskih zgrada u regiji jug Federacije Bosne i Hercegovine*, e-ZBORNİK (2022), **12**(23) p. 20-35 <https://hrcak.srce.hr/file/404760>
171. C. Balaras, E.G. Dascalaki, K.G. Droutsas, S. Kontoyiannidis, *Prevazilaženje razlike između stvarne i proračunate energije grijanja modeliranjem fonda stambenih zgrada metodom odozdo naviše (bottom-up)*, KGH (2017), **46**(1) p. 1-11 <https://doi.org/10.24094/kghc.017.46.1.59>
172. C. Demanuele, T. Tweddell, M. Davies. *Bridging the gap between predicted and actual energy performance in schools*. U: World renewable energy congress XI. 2010. Abu Dhabi, UAE Future Technology Press
173. A. Dasgupta, A. Prodromou, D. Mumovic, *Operational versus designed performance of low carbon schools in England: Bridging a credibility gap*, HVAC&R Res. (2012), **18**(1-2) p. 37-50 <https://doi.org/10.1080/10789669.2011.614318>
174. M. Jradi, *Dynamic energy modelling as an alternative approach for reducing performance gaps in retrofitted schools in Denmark*, Applied Sciences (2020), **10**(21) p. 7862 <https://doi.org/10.3390/app10217862>
175. A.P. Andaloro, R. Salomone, G. Ioppolo, L. Andaloro, *Energy certification of buildings: A comparative analysis of progress towards implementation in European countries*, Energy Policy (2010), **38**(10) p. 5840-5866 <https://doi.org/10.1016/j.enpol.2010.05.039>
176. M. Delghust, W. Roelens, T. Tanghe, Y. De Weerd, A. Janssens, *Regulatory energy calculations versus real energy use in high-performance houses*, Building Research & Information (2015), **43**(6) p. 675-690 <https://doi.org/10.1080/09613218.2015.1033874>
177. M. Sunikka-Blank, R. Galvin, *Introducing the prebound effect: the gap between performance and actual energy consumption*, Building Research & Information (2012), **40**(3) p. 260-273 <https://doi.org/10.1080/09613218.2012.690952>
178. R. Galvin, *Making the 'rebound effect' more useful for performance evaluation of thermal retrofits of existing homes: Defining the 'energy savings deficit' and the 'energy performance gap'*, Energy and Buildings (2014), **69** p. 515-524 <https://doi.org/10.1016/j.enbuild.2013.11.004>

179. P. Padey, K. Goulouti, G. Wagner, B. Périsset, S. Lasvaux, *Understanding the reasons behind the energy performance gap of an energy-efficient building, through a probabilistic approach and on-site measurements*, *Energies* (2021), **14**(19) p. 6178 <https://doi.org/10.3390/en14196178>
 180. A.S. Anđelković, M. Kljajić, D. Macura, V. Munćan, I. Mujan, M. Tomić, Ž. Vlaović, B. Stepanov, *Building energy performance certificate—a relevant indicator of actual energy consumption and savings?*, *Energies* (2021), **14**(12) p. 3455 <https://doi.org/10.3390/en14123455>
 181. V. Motuzienė, V. Lapinskienė, G. Rynkun, J. Bielskus, *Energy performance gap analysis in energy efficient residential buildings in Lithuania*, *Environmental and Climate Technologies* (2021), **25**(1) p. 610-620 <https://doi.org/10.2478/rtuct-2021-0045>
 182. Y.K. Kim, L. Bande, K.A. Tabet Aoul, H. Altan, *Dynamic energy performance gap analysis of a university building: Case studies at UAE university campus, UAE*, *Sustainability* (2020), **13**(1) p. 120 <https://doi.org/10.3390/su13010120>
 183. M. Herrando, D. Cambra, M. Navarro, L. de la Cruz, G. Millán, I. Zabalza, *Energy Performance Certification of Faculty Buildings in Spain: The gap between estimated and real energy consumption*, *Energy Conversion and Management* (2016), **125** p. 141-153 <https://doi.org/10.1016/j.enconman.2016.04.037>
 184. Republic of Croatia Ministry of Economy and Sustainable Development, *Energy in Croatia 2022*. 2022.
 185. Europski parlament i Vijeće, DIREKTIVA (EU) 2023/1791 EUROPSKOG PARLAMENTA I VIJEĆA. 2023.
 186. Europski parlament i Vijeće, Direktiva o energetske svojstvima zgrada (2024/1275/EU) 2024.
 187. Ministarstvo zaštite okoliša i energetike Republike Hrvatske, *Integrirani nacionalni energetski i klimatski plan Republike Hrvatske za razdoblje od 2021. do 2030. godine*. 2019.
 188. APN. EMIS Energy Management Information System. 2014; Dostupno na: <https://programme2014-20.interreg-central.eu/Content.Node/PROSPECT2030/PPL5-National-Energy-Management-Information-System-in-Croati.pdf>.
 189. F.z.z.o.i.e. učinkovitost. Projekt Poticanje energetske efikasnosti u Hrvatskoj. 2024; Dostupno na: <https://www.fzoeu.hr/hr/projekt-poticanje-energetske-efikasnosti-u-hrvatskoj/7741>.
 190. APN. EMIS Energy Management Information System. 2024; Dostupno na: <https://www.interregeurope.eu/sites/default/files/2024-03/Presentation%20by%20Davor%20Pinturic%CC%81%20on%20Smart%20Energy%20Information%20System.pdf>.
 191. Ministarstvo prostornog uređenja graditeljstva i državne imovine Republike Hrvatske. Informacijski sustav energetskih certifikata (IEC) Dostupno na: <https://eenergetskicertifikat.mgipu.hr/login.html>
 192. Ministarstvo prostornog uređenja graditeljstva i državne imovine Republike Hrvatske, *Program energetske obnove zgrada javnog sektora za razdoblje do 2030. godine*. 2022.
 193. I.C.E. Feedschools, Blok 2: Energetska učinkovitost u zgradama
- 2.4 Upravljanje energijom u zgradama.
194. Andrassy i sur., *Priručnik za energetske certificiranje zgrada*. 2010.
 195. Narodne novine, Tehnički propis o uštedi toplinske energije i toplinskoj zaštiti u zgradama (NN 79/05). 2005.
 196. Narodne novine, Tehnički propis o racionalnoj uporabi energije i toplinskoj zaštiti u zgradama (NN 110/08). 2008.
 197. Narodne novine, Tehnički propis o izmjeni Tehničkog propisa o racionalnoj uporabi energije i toplinskoj zaštiti u zgradama (NN 89/09). 2009.
 198. S. Vrček, *Tipologija izgradnje i podjela zgrada prema razdoblju gradnje i energetske potrebama*, *Tehnički glasnik* (2012), **6**(1) p. 60-64
 199. Hrvatski sabor, Državni pedagoški standard osnovnoškolskog sustava odgoja i obrazovanja (NN 63/2008) 2008.

200. Hrvatski sabor, Državni pedagoški standard srednjoškolskog sustava odgoja i obrazovanja. 2008.
201. Microsoft. Microsoft Excel. 2024; Dostupno na: <https://www.microsoft.com/en-us/microsoft-365/excel>.
202. Cloud Software Group Inc. TIBCO Statistica® 14.1.0. 2024; Dostupno na: <https://docs.tibco.com/products/tibco-statistica-14-1-0>.
203. M. Raatikainen, J.-P. Skön, K. Leiviskä, M. Kolehmainen, *Intelligent analysis of energy consumption in school buildings*, Applied Energy (2016), **165** p. 416-429 <https://doi.org/10.1016/j.apenergy.2015.12.072>
204. U. Desideri, S. Proietti, *Analysis of energy consumption in the high schools of a province in central Italy*, Energy and Buildings (2002), **34**(10) p. 1003-1016 [https://doi.org/10.1016/S0378-7788\(02\)00025-7](https://doi.org/10.1016/S0378-7788(02)00025-7)
205. G.K. Tso, K.K. Yau, *Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks*, Energy (2007), **32**(9) p. 1761-1768 <https://doi.org/10.1016/j.energy.2006.11.010>
206. N. Gaitani, C. Lehmann, M. Santamouris, G. Mihalakakou, P. Patargias, *Using principal component and cluster analysis in the heating evaluation of the school building sector*, Applied Energy (2010), **87**(6) p. 2079-2086 <https://doi.org/10.1016/j.apenergy.2009.12.007>
207. M. Issa, M. Attalla, J. Rankin, A. Christian, *Detailed analysis of electricity, water, and gas consumption quantities and costs in Toronto's public schools*, Canadian Journal of civil engineering (2010), **37**(1) p. 25-36 <https://doi.org/10.1139/L09-122>
208. P. Sedgwick, *Pearson's correlation coefficient*, Bmj (2012), **345** <https://doi.org/10.1136/bmj.e4483>
209. Laerd Statistics. Pearson Product-Moment Correlation. 2024; Dostupno na: <https://statistics.laerd.com/statistical-guides/pearson-correlation-coefficient-statistical-guide.php>.
210. P. Schober, C. Boer, L.A. Schwarte, *Correlation coefficients: appropriate use and interpretation*, Anesthesia & analgesia (2018), **126**(5) p. 1763-1768 10.1213/ANE.0000000000002864
211. R.K. Jain, K.M. Smith, P.J. Culligan, J.E. Taylor, *Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy*, Applied Energy (2014), **123** p. 168-178 <https://doi.org/10.1016/j.apenergy.2014.02.05>
212. C.E. Kontokosta, C. Tull, *A data-driven predictive model of city-scale energy use in buildings*, Applied energy (2017), **197** p. 303-317 <https://doi.org/10.1016/j.apenergy.2017.04.005>
213. I.M.M. Ghania, S. Ahmad, *Stepwise Multiple Regression Method to Forecast Fish Landing*, in International Conference on Mathematics Education Research 2010 (ICMER 2010) R.A. Tarmizi, Editor. 2010, Elsevier Procedia: Malacca, Malaysia, p. 549-554.
214. A.O. Sykes, *An introduction to regression analysis*. 1993.
215. R.J. Freund, W.J. Wilson, *Statistical methods*. 2nd ed. 2003, Cambridge, Massachusetts, SAD: Academic Press.
216. K.A. Marill, *Advanced statistics: linear regression, part II: multiple linear regression*, Academic Emergency Medicine (2004), **11**(1) p. 94-102 10.1197/j.aem.2003.09.006
217. M. Papić, *Primijenjena statistika u MS Excelu za ekonomiste, znanstvenike i neznalice*. 2005, Zagreb, Croatia: Zoro d.o.o.
218. A. Rana, A.S. Rawat, A. Bijalwan, H. Bahuguna. *Application of multi layer (perceptron) artificial neural network in the diagnosis system: a systematic review*. U: 2018 International conference on research in intelligent and computing in engineering (RICE). 2018. San Salvador, El Salvador: IEEE.10.1109/RICE.2018.8509069
219. B. Widrow, M.A. Lehr, *30 years of adaptive neural networks: perceptron, madaline, and backpropagation*, Proceedings of the IEEE (1990), **78**(9) p. 1415-1442 10.1109/5.58323

220. Y.-S. Park, S. Lek, *Artificial neural networks: Multilayer perceptron for ecological modeling*, Developments in Environmental Modelling (2016), **28** p. 123-140 <https://doi.org/10.1016/B978-0-444-63623-2.00007-4>
221. D.M. Hawkins, *The problem of overfitting*, Journal of chemical information and computer sciences (2004), **44**(1) p. 1-12 <https://doi.org/10.1021/ci0342472>
222. R.D. McKelvey, W. Zavoina, *A statistical model for the analysis of ordinal level dependent variables*, Journal of Mathematical Sociology (1975), **4**(1) p. 103-120 <https://doi.org/10.1080/0022250X.1975.9989847>
223. A. Schneider, G. Hommel, M. Blettner, *Linear regression analysis: part 14 of a series on evaluation of scientific publications*, Deutsches Ärzteblatt International (2010), **107**(44) p. 776 10.3238/arztebl.2010.0776
224. Z. Wang, A.C. Bovik, *Mean squared error: Love it or leave it? A new look at signal fidelity measures*, IEEE signal processing magazine (2009), **26**(1) p. 98-117 10.1109/MSP.2008.930649
225. I. Lulić, *The Use of Regression Analysis Method in Solving Problems from Engineering Practice*, in Faculty of Mechanical Engineering and Naval Architecture. 2014, University of Zagreb: Zagreb, Hrvatska.
226. D. Katić, *Modeli procjene troškova toplinske energije školskih zgrada na području Federacije Bosne i Hercegovine*. 2022, Građevinski i arhitektonski fakultet Osijek, Sveučilište Josipa Jurja Strossmayera u Osijeku: Osijek, Hrvatska.
227. M.G. Sobol, *Validation Strategies for Multiple Regression Analysis: Using the Coefficient of Determination*, Interfaces (1991), **21** p. 106-120 <https://doi.org/10.1287/inte.21.6.106>
228. R. Sailee, *Exploration of Variable Importance and Variable selection techniques in presence of correlated variables*, in Department of Mathematical Sciences. 2019, Rochester Institute of Technology, College of Science: Rochester, New York.
229. A. Cacabelos, P. Eguía, L. Febrero, E. Granada, *Development of a new multi-stage building energy model calibration methodology and validation in a public library*, Energy and Buildings (2017), **146** p. 182-199 <http://dx.doi.org/10.1016/j.enbuild.2017.04.071>
230. G.R. Small, R. Wong, *The Validity of Forecasting*, in The 8th Annual PRRES Conference in Christchurch, New Zealand, D. Parker, Editor. 2002, PRRES Inc. : Christchurch, New Zealand, p. 1-14.
231. P.A. Gonzalez, J.M. Zamarreno, *Prediction of hourly energy consumption in buildings based on a feedback artificial neural network*, Energy and Buildings (2005), **37**(6) p. 595-601 <https://doi.org/10.1016/j.enbuild.2004.09.006>
232. T.F. Dias, A. Kalbusch, E. Henning, *Factors influencing water consumption in buildings in southern Brazil*, Journal of Cleaner Production (2018), **184** p. 160-167 <https://doi.org/10.1016/j.jclepro.2018.02.093>
233. R.C. Balling Jr, P. Gober, N. Jones, *Sensitivity of residential water consumption to variations in climate: an intraurban analysis of Phoenix, Arizona*, Water resources research (2008), **44**(10) p. 1-11 <https://doi.org/10.1029/2007WR006722>
234. H. Chang, G.H. Parandvash, V. Shandas, *Spatial variations of single-family residential water consumption in Portland, Oregon*, Urban geography (2010), **31**(7) p. 953-972 <https://doi.org/10.2747/0272-3638.31.7.953>
235. E. Domene, D. Saurí, *Urbanisation and water consumption: Influencing factors in the metropolitan region of Barcelona*, Urban Studies (2006), **43**(9) p. 1605-1623 <https://doi.org/10.1080/00420980600749969>
236. S.L. Harlan, S.T. Yabiku, L. Larsen, A.J. Brazel, *Household water consumption in an arid city: Affluence, affordance, and attitudes*, Society and Natural Resources (2009), **22**(8) p. 691-709 <https://doi.org/10.1080/08941920802064679>

237. A. Tinker, S. Bame, R. Burt, M. Speed, *Impact of "non-behavioral fixed effects" on water use: Weather and economic construction differences on residential water use in Austin, Texas*, *Electronic Green Journal* (2005), **1**(22)
238. E.A. Wentz, P. Gober, *Determinants of small-area water consumption for the city of Phoenix, Arizona*, *Water Resources Management* (2007), **21** p. 1849-1863
<https://doi.org/10.1007/s11269-006-9133-0>
239. K. Bao, R. Padsala, D. Thrän, B. Schröter, *Urban water demand simulation in residential and non-residential buildings based on a CityGML data model*, *ISPRS international journal of geo-information* (2020), **9**(11) p. 642 <https://doi.org/10.3390/ijgi9110642>
240. W.e.A. Hussien, F.A. Memon, D.A. Savic, *Assessing and modelling the influence of household characteristics on per capita water consumption*, *Water Resources Management* (2016), **30** p. 2931-2955 <https://doi.org/10.1007/s11269-016-1314-x>
241. A. Grespan, J. Garcia, M.P. Brikalski, E. Henning, A. Kalbusch, *Assessment of water consumption in households using statistical analysis and regression trees*, *Sustainable Cities and Society* (2022), **87** p. 104186 <https://doi.org/10.1016/j.scs.2022.104186>
242. K.P.T.d. Silva, A. Kalbusch, E. Henning, G.A.L. Menezes, *Modeling water consumption in multifamily buildings: a case study in Southern Brazil*, *Urban Water Journal* (2021), **18**(10) p. 783-795 <https://doi.org/10.1080/1573062X.2021.1934040>
243. Richard M. Heiberger, B. Holland, *Statistical Analysis and Data Display*. 2015, New York, SAD: Springer.
244. H. Hens, W. Parijs, M. Deurinck, *Energy consumption for heating and rebound effects*, *Energy and Buildings* (2010), **42**(1) p. 105-110 <https://doi.org/10.1016/j.enbuild.2009.07.017>
245. M. Laskari, R.-F. de Masi, S. Karatasou, M. Santamouris, M.-N. Assimakopoulos, *On the impact of user behaviour on heating energy consumption and indoor temperature in residential buildings*, *Energy and Buildings* (2022), **255** p. 111657
<https://doi.org/10.1016/j.enbuild.2021.111657>
246. Z. Ma, H. Li, Q. Sun, C. Wang, A. Yan, F. Starfelt, *Statistical analysis of energy consumption patterns on the heat demand of buildings in district heating systems*, *Energy and Buildings* (2014), **85** p. 464-472 <https://doi.org/10.1016/j.enbuild.2014.09.04>
247. C. Filippín, F. Ricard, S.F. Larsen, *Evaluation of heating energy consumption patterns in the residential building sector using stepwise selection and multivariate analysis*, *Energy and Buildings* (2013), **66** p. 571-581 <https://doi.org/10.1016/j.enbuild.2013.07.054>
248. O.G. Santin, *Behavioural patterns and user profiles related to energy consumption for heating*, *Energy and Buildings* (2011), **43**(10) p. 2662-2672
<https://doi.org/10.1016/j.enbuild.2011.06.024>
249. T. Catalina, J. Virgone, V. Iordache. Study on the impact of the building form on the energy consumption. U: Building Simulation 2011. 2011. Sydney, Australija: IBPSA
250. R. Pino-Mejías, A. Pérez-Fargallo, C. Rubio-Bellido, J.A. Pulido-Arcas, *Comparison of linear regression and artificial neural networks models to predict heating and cooling energy demand, energy consumption and CO2 emissions*, *Energy* (2017), **118** p. 24-36
<https://doi.org/10.1016/j.energy.2016.12.022>
251. M. Aksoezen, M. Daniel, U. Hassler, N. Kohler, *Building age as an indicator for energy consumption*, *Energy and Buildings* (2015), **87** p. 74-86
<https://doi.org/10.1016/j.enbuild.2014.10.074>
252. T. Sekki, M. Airaksinen, A. Saari, *Measured energy consumption of educational buildings in a Finnish city*, *Energy and Buildings* (2015), **87** p. 105-115
<https://doi.org/10.1016/j.enbuild.2014.11.032>
253. P. Tuominen, R. Holopainen, L. Eskola, J. Jokisalo, M. Airaksinen, *Calculation method and tool for assessing energy consumption in the building stock*, *Building and Environment* (2014), **75** p. 153-160 <https://doi.org/10.1016/j.buildenv.2014.02.001>

254. F. Filippidou, N. Nieboer, H. Visscher, *Effectiveness of energy renovations: a reassessment based on actual consumption savings*, Energy Efficiency (2019), **12** p. 19-35 <https://doi.org/10.1007/s12053-018-9634-8>
255. L. La Fleur, P. Rohdin, B. Moshfegh, *Energy use and perceived indoor environment in a Swedish multifamily building before and after major renovation*, Sustainability (2018), **10**(3) p. 766 <https://doi.org/10.3390/su10030766>
256. L. Troup, R. Phillips, M.J. Eckelman, D. Fannon, *Effect of window-to-wall ratio on measured energy consumption in US office buildings*, Energy and Buildings (2019), **203** p. 109434 <https://doi.org/10.1016/j.enbuild.2019.109434>
257. C. Marino, A. Nucara, M. Pietrafesa, *Does window-to-wall ratio have a significant effect on the energy consumption of buildings? A parametric analysis in Italian climate conditions*, Journal of Building Engineering (2017), **13** p. 169-183 <https://doi.org/10.1016/j.jobbe.2017.08.001>
258. Q. Yang, M. Liu, C. Shu, D. Mmereki, M. Uzzal Hossain, X. Zhan, *Impact Analysis of Window-Wall Ratio on Heating and Cooling Energy Consumption of Residential Buildings in Hot Summer and Cold Winter Zone in China*, Journal of Engineering (2015), **2015**(1) p. 538254 <https://doi.org/10.1155/2015/538254>
259. K. Lylykangas. Shape factor as an indicator of heating energy demand. U: 15. Internationales Holzbau-Forum. 2009. Garmisch-Partenkirchen, Austrija: Hochschule für Architektur, Bau und Holz
260. P. Depecker, C. Menezo, J. Virgone, S. Lepers, *Design of buildings shape and energetic consumption*, Building and Environment (2001), **36**(5) p. 627-635 [https://doi.org/10.1016/S0360-1323\(00\)00044-5](https://doi.org/10.1016/S0360-1323(00)00044-5)
261. J. Liu, M. Heidarinejad, S. Gracik, J. Srebric, *The impact of exterior surface convective heat transfer coefficients on the building energy consumption in urban neighborhoods with different plan area densities*, Energy and Buildings (2014), **86** p. 449-463 <https://doi.org/10.1016/j.enbuild.2014.10.062>
262. J. Adamczyk, R. Dylewski, *Changes in heat transfer coefficients in Poland and their impact on energy demand-an environmental and economic assessment*, Renewable and Sustainable Energy Reviews (2017), **78** p. 530-538 <https://doi.org/10.1016/j.rser.2017.04.091>
263. J. Horvat, J. Mijoč, *Osnove statistike*. 2012, Zagreb, Hrvatska: Naklada Ljevak.
264. L. Breiman, *Random forests*, Machine learning (2001), **45** p. 5-32 <https://doi.org/10.1023/A:1010933404324>
265. E. Lewinson, *Python for Finance Cookbook: Over 50 recipes for applying modern Python libraries to financial data analysis*. 2020, Birmingham, Ujedinjeno Kraljevstvo: Packt Publishing Ltd.
266. J. Jokić, S. Martinčić-Ipšić, *Primjena šume slučajnih stabala za predviđanje ishoda šahovske partije reprezentirane kompleksnom mrežom*, Zbornik Veleučilišta u Rijeci (2019), **7**(1) p. 31-52 <https://doi.org/10.31784/zvr.7.1.4>
267. R. Caruana, A. Niculescu-Mizil. An empirical comparison of supervised learning algorithms. U: Proceedings of the 23rd international conference on Machine learning. 2006. Pittsburgh, Pennsylvania, SAD: Association for Computing Machinery, New York, NY, SAD
268. A.M. Youssef, H.R. Pourghasemi, Z.S. Pourtaghi, M.M. Al-Katheeri, *Landslide susceptibility mapping using random forest, boosted regression tree, classification and regression tree, and general linear models and comparison of their performance at Wadi Tayyah Basin, Asir Region, Saudi Arabia*, Landslides (2016), **13** p. 839-856 <https://doi.org/10.1007/s10346-015-0614-1>
269. P. Probst, A.-L. Boulesteix, *To tune or not to tune the number of trees in random forest*, Journal of Machine Learning Research (2018), **18**(181) p. 1-18 <https://doi.org/10.48550/arXiv.1705.05654>
270. Ministarstvo zaštite okoliša prostornog uređenja i graditeljstva. Pravilnik o energetsom certificiranju zgrada (NN 36/2010). 2008; Dostupno na: https://narodne-novine.nn.hr/clanci/sluzbeni/2008_10_113_3293.html.

271. Ministarstvo prostornoga uređenja graditeljstva i državne imovine Republike Hrvatske. Pravilnik o energetsom pregledu zgrade i energetsom certificiranju (NN 88/17, 90/20, 01/21, 45/21). 2017; Dostupno na: <https://www.zakon.hr/cms.htm?id=45406>.
272. HEP Plin d.o.o. Gas prices. 2024; Dostupno na: <https://www.hep.hr/plin/cijene-plina-i-usluga/cijene-plina/1605>.
273. HEP-TOPLINARSTVO d.o.o. Prices - Central Heating System - Osijek. 2024; Dostupno na: <https://www.hep.hr/toplinarstvo/UserDocsImages/dokumenti/krajnji-kupci/cijene/Cjenik%20od%20110.2023/CTS%20Osijek%20od%201.10.2023..pdf>.
274. M. Teni, H. Krstić, P. Kosiński, *Review and comparison of current experimental approaches for in-situ measurements of building walls thermal transmittance*, Energy and Buildings (2019), **203** p. 109417 <https://doi.org/10.1016/j.enbuild.2019.109417>
275. D. Majcen, L. Itard, H. Visscher, *Theoretical vs. actual energy consumption of labelled dwellings in the Netherlands: Discrepancies and policy implications*, Energy Policy (2013), **54** p. 125-136 <https://doi.org/10.1016/j.enpol.2012.11.008>
276. D. Majcen, L. Itard, H. Visscher, *Actual and theoretical gas consumption in Dutch dwellings: What causes the differences?*, Energy Policy (2013), **61** p. 460-471 <https://doi.org/10.1016/j.enpol.2013.06.018>
277. L. Evangelisti, C. Guattari, P. Gori, R. De Lieto Vollaro, *In situ thermal transmittance measurements for investigating differences between wall models and actual building performance*, Sustainability (2015), **7**(8) p. 10388-10398 <https://doi.org/10.3390/su70810388>
278. P. van den Brom, A. Meijer, H. Visscher, *Performance gaps in energy consumption: household groups and building characteristics*, Building Research & Information (2018), **46**(1) p. 54-70 <https://doi.org/10.1080/09613218.2017.1312897>
279. Ministarstvo prostornog uređenja graditeljstva i državne imovine Republike Hrvatske, Metodologija provođenja energetskeg pregleda zgrada. 2021.
280. Ministarstvo prostornoga uređenja graditeljstva i državne imovine, Pravilnik o metodama procjene vrijednosti nekret-nina (NN 105/2015). 2015.
281. M. Amrouni Hosseini, M. Ravanshadnia, M. Rahimzadegan, S. Ramezani, *Next-Generation Building Condition Assessment: BIM and Neural Network Integration*, Journal of Performance of Constructed Facilities (2024), **38**(6) p. 04024050 <https://doi.org/10.1061/JPCFEV.CFENG-4828>
282. Z. Wang, Y. Wang, R. Zeng, R.S. Srinivasan, S. Ahrentzen, *Random Forest based hourly building energy prediction*, Energy and Buildings (2018), **171** p. 11-25 <https://doi.org/10.1016/j.enbuild.2018.04.008>
283. J. Ma, J.C. Cheng, *Identifying the influential features on the regional energy use intensity of residential buildings based on Random Forests*, Applied Energy (2016), **183** p. 193-201 <https://doi.org/10.1016/j.apenergy.2016.08.096>
284. J. Lin, S. Lu, X. He, F. Wang, *Analyzing the impact of three-dimensional building structure on CO2 emissions based on random forest regression*, Energy (2021), **236** p. 121502 [10.1016/j.energy.2021.121502](https://doi.org/10.1016/j.energy.2021.121502)
285. M. Zekić-Sušac, A. Has, M. Knežević, *Predicting energy cost of public buildings by artificial neural networks, CART, and random forest*, Neurocomputing (2021), **439** p. 223-233 <https://doi.org/10.1016/j.neucom.2020.01.124>
286. T.R. Tooke, N.C. Coops, J. Webster, *Predicting building ages from LiDAR data with random forests for building energy modeling*, Energy and Buildings (2014), **68** p. 603-610 <https://doi.org/10.1016/j.enbuild.2013.10.004>
287. Y. Fang, X. Lu, H. Li, *A random forest-based model for the prediction of construction-stage carbon emissions at the early design stage*, Journal of Cleaner Production (2021), **328** p. 129657 <https://doi.org/10.1016/j.jclepro.2021.129657>

288. Agencija za pravni promet i posredovanje nekretninama. Informacijski sustav za gospodarenje energijom - ISGE. 2015 [cited 2024 15. siječanj]; Dostupno na: <https://apn.hr/gospodarenje-energijom-isge/informacijski-sustav-za-gospodarenje-energijom>
289. D. Bebić, L. Stazić, A. Mišura, I. Komar, *EDD—economic benefit analysis of extending dry docking interval*, Transactions on Maritime Science (2018), 7(02) p. 164-173 <https://doi.org/10.7225/toms.v07.n02.006>

Curriculum vitae

Hana Begić Juričić rođena je 3. 6.1996. godine u Osijeku. Preddiplomski sveučilišni studij Građevinarstvo (smjer opći) završila je 2018. godine na Građevinskom fakultetu Osijek, a diplomski sveučilišni studij Građevinarstvo (smjer Organizacija, tehnologija i menadžment građenja) završila je 2020. godine na Građevinskom i arhitektonskom fakultetu Osijek te stekla akademski stupanj magistre građevinarstva. Dobitnica je dvije Dekanove nagrade, stipendije za darovite studente i potpore Osječko-baranjske županije, Stipendije Hrvatske komore inženjera građevinstva najboljim studentima, stipendije Ministarstva znanosti i obrazovanja za izvrsnost te stipendije Sveučilišta J. J. Strossmayera u Osijeku za izvrsnost. Prvo radno iskustvo stječe tijekom studija (srpanj 2019. - rujan 2020.) kao pomoćnica ovlaštenog sudskog vještaka i procjenitelja nekretnina te ovlaštenog inženjera građevinarstva u DIT GRUPA D.O.O. Nakon studija zapošljava se na Građevinskom i arhitektonskom fakultetu Osijek kao asistentica na zamjeni (listopad 2020. - rujan 2021.). Od listopada 2021. godine do prosinca 2022. godine bila je vanjska suradnica u zvanju asistentice. Od prosinca 2022. godine do danas je asistentica na Građevinskom i arhitektonskom fakultetu Osijek za kolegije Upravljanje projektima, Energija u zgradarstvu i Elementi Visokogradnje. Godine 2020. upisala je Poslijediplomski sveučilišni studij Građevinarstvo – modul Organizacija, tehnologija i menadžment građenja na Građevinskom i arhitektonskom fakultetu Osijek. Program Pedagoško-psihološko-didaktičko-metodičke izobrazbe na Filozofskom fakultetu Osijek upisala je u siječnju 2022. i završila u lipnju 2022. godine. Sudjelovala je s izlaganjima na 8 znanstvenih skupova te je održala 2 stručne radionice. Objavila je 8 radova u časopisima te 8 u zbornicima skupova.

