ENERGETSKA UČINKOVITOST KAO POTPORA UPRAVLJANJU ZGRADAMA JAVNOG SEKTORA

Has, Adela

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Economics in Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:145:096123

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

EFOS REPOSITORY - Repository of the Faculty of Economics in Osijek

Sveučilište Josipa Jurja Strossmayera u Osijeku
Ekonomski fakultet u Osijeku
Poslijediplomski međusveučilišni interdisciplinarni studij
PODUZETNIŠTVO I INOVATIVNOST

Adela Has

ENERGETSKA UČINKOVITOST KAO POTPORA UPRAVLJANJU ZGRADAMA JAVNOG SEKTORA

DOKTORSKA DISERTACIJA

Osijek, 2022.

Sveučilište Josipa Jurja Strossmayera u Osijeku
Ekonomski fakultet u Osijeku
Poslijediplomski međusveučilišni interdisciplinarni studij
PODUZETNIŠTVO I INOVATIVNOST

Adela Has

ENERGETSKA UČINKOVITOST KAO POTPORA UPRAVLJANJU ZGRADAMA JAVNOG SEKTORA

DOKTORSKA DISERTACIJA

Mentor: izv. prof. dr. sc. Ivana Đurđević Babić

Osijek, 2022.

Josip Juraj Strossmayer University of Osijek
Faculty of Economics in Osijek
Inter-university postgraduate interdisciplinary program
ENTREPRENEURSHIP AND INNOVATIVENESS

Adela Has

ENERGY EFFICIENCY AS SUPPORT FOR MANAGING BUILDINGS IN THE PUBLIC SECTOR

DOCTORAL THESIS

Mentor: Ivana Đurđević Babić, PhD

Osijek, 2022

IZJAVA

O AKADEMSKOJ ČESTITOSTI, PRAVU PRIJENOSA INTELEKTUALNOG VLASNIŠTVA, SUGLASNOSTI ZA OBJAVU U INSTITUCIJSKIM REPOZITORIJIMA I ISTOVJETNOSTI DIGITALNE I TISKANE VERZIJE RADA

1. Kojom izjavljujem i svojim potpisom potvrđujem da je_____ doktorski (navesti vrstu rada: završni / diplomski / specijalistički / doktorski) rad isključivo rezultat osobnoga rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu. Potvrđujem poštivanje nepovredivosti autorstva te točno citiranje radova drugih autora i referiranje na njih.
2. Kojom izjavljujem da je Ekonomski fakultet u Osijeku, bez naknade u vremenski i teritorijalno neograničenom opsegu, nositelj svih prava intelektualnoga vlasništva u odnosu na navedeni rad pod licencom *Creative Commons Imenovanje – Nekomercijalno – Dijeli pod istim uvjetima 3.0 Hrvatska*.
3. Kojom izjavljujem da sam suglasan/suglasna da se trajno pohrani i objavi moj rad u institucijskom digitalnom repozitoriju Ekonomskoga fakulteta u Osijeku, repozitoriju Sveučilišta Josipa Jurja Strossmayera u Osijeku te javno dostupnom repozitoriju Nacionalne i sveučilišne knjižnice u Zagrebu (u skladu s odredbama Zakona o znanstvenoj djelatnosti i visokom obrazovanju, NN br. 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15).
4. Izjavljujem da sam autor/autorica predanog rada i da je sadržaj predane elektroničke datoteke u potpunosti istovjetan s dovršenom tiskanom verzijom rada predanom u svrhu obrane istog.

Ime i prezime studenta/studentice: Adela Has

JMBAG: 258

OIB: 47763620526

e-mail za kontakt: adela.has@efos.hr

Naziv studija: Poslijediplomski međusveučilišni interdisciplinarni studij

PODUZETNIŠTVO I INOVATIVNOST

Naslov rada: Energetska učinkovitost kao potpora upravljanju zgradama javnog sektora

Mentor/mentorica rada: izv. prof. dr. sc. Ivana Đurđević Babić

U Osijeku, 09.05.2022. godine

Potpis Adela Has

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku **Doktorska disertacija**
Ekonomski fakultet u Osijeku

Znanstveno područje: Društvene znanosti
Znanstveno polje: Ekonomija

ENERGETSKA UČINKOVITOST KAO POTPORA UPRAVLJANJU ZGRADAMA JAVNOG SEKTORA

Adela Has

Disertacija je izrađena u: Osijeku

Mentor: izv. prof. dr. sc. Ivana Đurđević Babić

Kratki sažetak doktorske disertacije:
Briga o energiji i upravljanje energijom temeljni su preduvjeti za ostvarenje održivog razvoja. Najveći pojedinačni potrošači energije su zgrade, a posebno zgrade javnog sektora kod kojih ne postoji odgovarajući model za upravljanje i nadzor potrošnje energije kao i alociranje resursa prilikom provođenja mjera energetske obnove. U disertaciji istraženo je nekoliko ključnih pitanja vezanih uz potrošnju energije u zgradama javnog sektora: (1) postoji li odstupanje između stvarne potrošnje energije zgrada javnog sektora u Hrvatskoj i procijenjene potrošnje prema energetskim certifikatima zgrada javnog sektora, (2) kako smanjiti odstupanja u predviđanju potrošnje energije u zgradama javnog sektora pomoću prediktivnog modela temeljenog na metodama strojnog učenja i (3) koji su glavni prediktori potrošnje energije javnih zgrada koji mogu poslužiti za donošenje odluka o mjerama i ulaganjima u energetsku obnovu javnog sektora. Kako bi se smanjila postojeća odstupanja proračunske od stvarne potrošnje kreiran je model za predviđanje potrošnje energije javnih zgrada koji može biti podloga za procjene financijskih ušteda i donošenja akcijskih planova energetske učinkovitosti, što je važno kako za upravljanje financijskim resursima u javnom sektoru, tako i za povećanje učinkovitosti cijelog javnog sektora. Uvođenjem ovakvog inovativnog načina za upravljanje energijom izravno se doprinosi promicanju poduzetničke kulture u javnom sektoru i educiranju šire javnosti o važnosti energetske učinkovitosti.

Broj stranica: 179
Broj slika: 30
Broj tablica: 35
Broj literaturnih navoda: 155
Jezik izvornika: hrvatski
Ključne riječi: *duboko učenje, energetska učinkovitost, inovativnost, javni sektor, strojno učenje*

Datum obrane: 09.05.2022.

Stručno povjerenstvo za obranu:
1. prof. dr. sc. Slavica Singer
2. izv. prof. dr. sc. Hrvoje Krstić
3. prof. dr. sc. Božidar Kliček
4. prof. dr. sc. Sunčica Oberman Peterka (zamjena)

Disertacija je pohranjena u: Nacionalnoj i sveučilišnoj knjižnici Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; Gradskoj i sveučilišnoj knjižnici Osijek, Europska avenija 24, Osijek; Sveučilištu Josipa Jurja Strossmayera u Osijeku, Trg sv. Trojstva 3, Osijek; Ekonomskom fakultetu u Osijeku, Trg Lj. Gaja 7, Osijek

BASIC DOCUMENTATION CARD

Josip Juraj Strossmayer University of Osijek **PhD thesis**
Faculty of Economics in Osijek

Scientific Area: Social sciences
Scientific Field: Economics

ENERGY EFFICIENCY AS SUPPORT FOR MANAGING BUILDINGS IN THE PUBLIC SECTOR

Adela Has

Thesis performed at: Osijek

Supervisor: Ivana Đurđević Babić, PhD

Short abstract:
Taking care of and managing energy are the basic requirements for achieving sustainable development. The largest individual energy consumers are buildings, especially public buildings, for which there is no satisfactory model for managing and controlling energy consumption and resource allocation in energy reconstruction measures. The dissertation will investigate (1) whether there is a gap between real energy consumption of public buildings in Croatia and energy consumption that is estimated during energy certification of buildings in the public sector, (2) how to reduce the deviation in predicting energy consumption of buildings in the public sector by predictive models based on machine learning methods, and (3) what are the important predictors of energy consumption of public buildings that can be used for making decisions on measures and investments in energy reconstruction of public sector. The aim is to create a model for predicting the energy consumption of public buildings that will serve as a platform for estimating financial savings and defining action plans of energy efficiency, which is important for the financial resources management of the public sector, as well as for increasing efficiency of the whole public sector. Such an innovative way of managing energy would increase entrepreneurship culture the in public sector and would educate the public about the importance of energy efficiency.

Number of pages: 179
Number of figures: 30
Number of tables: 35
Number of references: 155
Original in: Croatian
Key words: *deep learning, energy efficiency, innovation, machine learning, public sector*

Date of the thesis defense: 09.05.2022.

Reviewers:
1. Slavica Singer, PhD
2. Hrvoje Krstić, PhD
3. Božidar Kliček, PhD
4. Sunčica Oberman Peterka, PhD (substitute)

Thesis deposited in: National and University Library in Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; City and University Library Osijek, Europska avenija 24, Osijek; Josip Juraj Strossmayer University of Osijek, Trg sv. Trojstva 3, Osijek; Faculty of Economics in Osijek, Trg Lj. Gaja 7, Osijek

Energetska učinkovitost kao potpora upravljanju zgradama javnog sektora

SAŽETAK

Briga o energiji i upravljanje energijom temeljni su preduvjeti za ostvarenje održivog razvoja. Najveći pojedinačni potrošači energije su zgrade, a posebno zgrade javnog sektora kod kojih ne postoji odgovarajući model za upravljanje i nadzor potrošnje energije kao i alociranje resursa prilikom provođenja mjera energetske obnove. U disertaciji istraženo je nekoliko ključnih pitanje vezanih uz potrošnju energije u zgradama javnog sektora: (1) postoji li odstupanje između stvarne potrošnje energije kod zgrada javnog sektora u Hrvatskoj i procijenjene potrošnje prema energetskim certifikatima zgrada javnog sektora, (2) kako smanjiti odstupanja u predviđanju potrošnje energije u zgradama javnog sektora pomoću prediktivnog modela temeljenog na metodama strojnog učenja i (3) koji su glavni prediktori potrošnje energije javnih zgrada koji mogu poslužiti za donošenje odluka o mjerama i ulaganjima u energetsku obnovu javnog sektora. Kako bi se smanjila postojeća odstupanja proračunske od stvarne potrošnje kreiran je model za predviđanje potrošnje energije javnih zgrada koji može biti podloga za procjene financijskih ušteda i donošenje akcijskih planova energetske učinkovitosti, što je važno kako za upravljanje financijskim resursima u javnom sektoru, tako i za povećanje učinkovitosti cijelog javnog sektora. Uvođenjem ovakvog inovativnog načina za upravljanje energijom izravno se doprinosi promicanju poduzetničke kulture u javnom sektoru i educiranju šire javnosti o važnosti energetske učinkovitosti.

Ključne riječi: *duboko učenje, energetska učinkovitost, inovativnost, javni sektor, strojno učenje*

Energy efficiency as support for managing buildings in the public sector

ABSTRACT

Taking care of and managing energy are the basic requirements for achieving sustainable development. The largest individual energy consumers are buildings, especially public buildings, for which there is no satisfactory model for managing and controlling energy consumption and resource allocation in energy reconstruction measures. The dissertation will investigate (1) whether there is a gap between real energy consumption of public buildings in Croatia and energy consumption that is estimated during energy certification of buildings in the public sector, (2) how to reduce the deviation in predicting energy consumption of buildings in the public sector by predictive models based on machine learning methods, and (3) what are the important predictors of energy consumption of public buildings that can be used for making decisions on measures and investments in energy reconstruction of public sector. The aim is to create a model for predicting the energy consumption of public buildings that will serve as a platform for estimating financial savings and defining action plans of energy efficiency, which is important for the financial resources management of the public sector, as well as for increasing efficiency of the whole public sector. Such an innovative way of managing energy would increase entrepreneurship culture the in public sector and would educate the public about the importance of energy efficiency.

Keywords: *deep learning, energy efficiency, innovation, machine learning, public sector*

SADRŽAJ

1. UVOD 1
1.1. Istraživački problem 3
1.2. Cilj istraživanja 6
1.3. Struktura rada 7

2. TEORIJSKA PODLOGA 8
2.1. Potrošnja energije i energetska učinkovitost 8
2.1.1. Potrošnja energije i teorije ekonomskog rasta 11
2.1.2. Potrošnja energije i politike Europske unije 15
2.2. Energetska učinkovitost 16
2.3. Energetska učinkovitost u sektoru zgradarstva 26
2.3.1. Odstupanje u potrošnji energije u zgradama 33
2.4. Uloga javnog sektora u promicanju energetske učinkovitosti u zgradarstvu 37
2.4.1. Problematika zgrada javnog sektora i energetske učinkovitosti s osvrtom na specifičnosti hrvatskog konteksta 41

3. METODOLOGIJA RADA 51
3.1. Istraživački pristup, dizajn i metode 52
3.2. Podaci 60
3.2.1. Prikupljanje, predprocesiranje i vizualizacija podataka 60
3.3. Metodologija umjetnih neuronskih mreža 72
3.3.1. Višeslojna perceptron neuronska mreža 79
3.3.2. Duboko učenje i duboke neuronske mreže 82
3.3.3. Koraci u izgradnja modela neuronske mreže 85
3.3.4. Pregled empirijskih istraživanja u istraživanom području temeljenih na strojnom učenju 87

4. OPIS ISTRAŽIVANJA I REZULTATI ISTRAŽIVANJA 92
4.1. Odstupanje u potrošnji energije u zgradama javnog sektora u Republici Hrvatskoj 92
4.1.1. Priprema uzorka i ciljne varijable 93
4.1.2. Odstupanje u potrošnji energije u zgradama javnog sektora – točnost postojećih modela 103
4.2. Izrada modela strojnog učenja za predviđanje potrošnje energije zgrada javnog sektora 107
4.2.1. Predprocesiranje podataka i definiranje modela strojnog učenja 109
4.2.2. Selekcija varijabli 116

4.2.3. Izgradnja modela za klasificiranje zgrada javnog sektora prema stvarnoj potrošnji energije 118
4.2.4. Rezultati modela strojnog učenja za klasificiranje zgrada javnog sektora prema potrošnji stvarne primarne energije 124
4.2.5. Analiza predloženog modela za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji energije 128

5. RASPRAVA 137

6. ZAKLJUČAK 149

LITERATURA 152
POPIS SLIKA 164
PRILOZI 167

1. UVOD

Energetska učinkovitost aktualno je istraživačko područje unutar znanstvene zajednice. Postoji više razloga zbog kojih dolazi do značajnijeg interesa istraživača. U proteklom desetljeću oscilacije u cijenama na tržištu energenata ukazale su na osjetljivost i ovisnost gospodarstava o energentima, ali isto tako odrazile su se i na ostala područja kao što je socijalni sustav pojavom nove vrste siromaštva – energetskog siromaštva. Slijedom toga dolazi do sve većeg promišljanja o važnosti upravljanja energijom, njenom potrošnjom, osiguranju energetske sigurnosti, obnovljivim izvorima energije. Planirano i učinkovito upravljanje energijom postalo je preduvjet za razvoj društva u cjelini i jedan od temelja za ostvarenje konkurentnosti, energetske i ekonomske stabilnosti te održivog razvoja. Pitanje energetske sigurnosti jedno je od ključnih pitanja prilikom planiranja nacionalnih strategija i politika. Važnost energetskog pitanja i upravljanja potrošnjom energije i učinkovitijeg korištenja prepoznato je na i razini Europske unije (EU). Značajan doprinos po pitanju energetske učinkovitosti u zemljama članicama EU napravljen je donošenjem *Direktive 2012/27/EU o energetskoj učinkovitosti*. Važnost je *Direktive 2012/27/EU o energetskoj učinkovitosti* u tome što definira sustav obveze energetske učinkovitosti i alternativni pristup sustavu obveze energetske učinkovitosti. Pojednostavljeno, definira specifične politike i mjere koje zemlje članice moraju usvojiti i provesti kroz svoje nacionalne politike kako bi ostvarile uštede u potrošnji energije. Važno je istaknuti da problem energetske učinkovitost nije isključivo vezan uz jedan gospodarski sustav, sektor ili poslovni proces već predstavlja problem koji se može identificirati u svemu navedenom. Energetska učinkovitost najčešće se promatra kroz sektor industrije, zgradarstva, transporta, rasvjete i obnovljivih izvora energije. Povećanjem razine energetske učinkovitosti u bilo kojem od navedenih područja izravno se ostvaruju financijske i ekološke koristi, a ujedno se osigurava i veća energetska sigurnost nacionalnog gospodarstva.

Definiranje energetske učinkovitosti s fokusom na sektor zgradarstva jedna je od polaznih točaka ove doktorske disertacije. Energetska učinkovitost smatra se sponom za ublažavanje odnosa između gospodarskog rasta i povećane potrošnje energije (Al-Mofleh i suradnici, 2009). Poznato tumačenje energetske učinkovitosti dao je Patterson (1996) koji definira energetsku učinkovitost kao „*omjer korisnog izlaza (engl. outputa) nekog procesa i uložene energije u taj isti proces*“. Drugim riječima, energetska učinkovitost označava korištenje manje energije za proizvodnju istog izlaza.

Ovom doktorskom disertacijom istražena je energetska učinkovitosti sektora zgradarstva s fokusom na nestambene zgrade. Sektor zgradarstva kao predmet istraživačkog interesa nametnuo se zbog nekoliko razloga. Zgrade predstavljaju jedan od najvećih pojedinačnih potrošača energije te čine gotovo 40 % ukupne potrošnje energije (Tommerup i suradnici, 2007). U Republici Hrvatskoj gotovo 70 % zgrada izgrađeno je prije 1980. godine i kao takve ne zadovoljavaju postojeće energetske standarde (Krstić i Teni, 2018). U provedenom istraživanju usmjerilo se na nestambene zgrade i to isključivo na zgrade koje se po svojoj definiciji smatraju zgradama javnog sektora. Zgrade javnog sektora prepoznate su u *Direktivi 2012/27/EU o energetskoj učinkovitosti* kao značajan potencijal za postizanje ušteda u potrošnji energije. Na temelju navedene Direktive za zemlje članice proizašla je obveza, počevši od 1. siječnja 2014. godine, *„obnoviti 3 % ukupne površine poda grijanih i/ili hlađenih zgrada u vlasništvu i uporabi središnje vlasti“* (Vlada Republike Hrvatske, 2017).

Zgrade javnog sektora u Republici Hrvatskoj su definirane kroz nekoliko različitih Zakona, pravilnika i odluka (*Zakon o gradnji (NN 153/13, 20/17, 39/19, 125/19)*; *Odluka o donošenju Programa energetske obnove zgrada javnog sektora za razdoblje 2016. – 2020. (NN 22/2017-508); Pravilnik o energetskom pregledu zgrade i energetskom certificiranju (NN 88/17, NN 90/20, NN 01/21, NN 45/21)).* U ovom istraživanju za definiranje zgrada javnog sektora preuzelo se tumačenje iz dokumenta pod nazivom *„Odluka o donošenju Programa energetske obnove zgrada javnog sektora za razdoblje 2016. – 2020.“* koji je objavljen u NN 22/2017-508 prema kojem zgrade javnog sektora obuhvaćaju „*zgrade u vlasništvu javnog sektora u kojima se obavljaju društvene djelatnosti (odgoja, obrazovanja, prosvjete, znanosti, kulture, sporta, zdravstva i socijalne skrbi), djelatnosti državnih tijela i organizacija kao i tijela i organizacija lokalne i područne (regionalne) samouprave, djelatnosti pravnih osoba s javnim ovlastima, zatim zgrade za stanovanje zajednica, zgrade udruga građana i zgrade vjerskih zajednica*.“ (Vlada Republike Hrvatske, 2017).

Provedenim istraživanjem uočene su prepreke u postojećim sustavima za upravljanje potrošnjom energije u zgradama javnog sektora i provođenju programa energetske obnove javnog sektora te su predložena rješenja u vidu modela koji može poslužiti kao inteligentna potpora i poticaj u procesima povećanja energetske učinkovitosti u zgradama javnog sektora.

1.1. Istraživački problem

U Republici Hrvatskoj uspostavljen je zakonodavni okvir vezan uz energetsku učinkovitost, osnovana su tijela za praćenje energetske učinkovitosti, izrađeni nacionalni planovi za energetsku učinkovitost i postavljeni ciljevi za povećanje energetske učinkovitosti. Kako bi se poboljšala energetska svojstva zgrada javnog sektora periodično se raspisuju natječaji za energetsku obnovu na koje se prijavljuju korisnici zgrada javnog sektora s ciljem povećanja razine energetske učinkovitosti putem energetske obnove. Utvrđivanje postojećeg stanja zgrada javnog sektora prvi je korak ka ostvarenju veće energetske učinkovitosti. Provođenje postupka energetskog certificiranja obvezno je za sve zgrade javnog sektora veće od 250 m^2 i njime se utvrđuje *specifična godišnja potrebna toplinska energija za grijanje za referentne klimatske podatke* izražena u kWh/m^2a te se na temelju toga nestambene zgrade svrstavaju u energetske razrede od A + do G, gdje oznaka A + predstavlja energetski razred s najboljim energetskim svojstvima, a oznaka G označava zgrade s najlošijim energetskim svojstvima (Pravilnik o energetskom pregledu zgrade i energetskom certificiranju, NN 88/17, NN 90/20, NN 01/21, NN 45/21). Unatoč uspostavljenom zakonodavnom okviru vezano uz energetsku učinkovitost postoje prepreke na putu ostvarenja veće energetske učinkovitosti u zgradama javnog sektora.

Nedostatak informacija o energetskom stanju zgrade, unatoč jasno propisanoj zakonskoj obvezi energetskog certificiranja zgrada koje imaju više od 250 m^2, ukazuje na marginalizaciju pitanja energetske učinkovitosti u javnom sektoru kod svih uključenih dionika. Međutim, i kod zgrada za koje je energetski razred poznat, proračunska potrošnja energije ponekad je znatno manja od stvarne potrošnje energije koju generira pojedina zgrada te ne prikazuje stvarno energetsko stanje zgrade.

U ovom procesu mogu se identificirati dva dionika: zakonodavno tijelo koje je zaduženo za provedbu i upravljanje potrošnjom energije u zgradama javnog sektora te korisnici/ upravitelji zgrada javnog sektora. Korisnici zgrada javnog sektora nisu dovoljno osviješteni o dugoročno pozitivnim efektima koji proizlaze povećanjem energetske učinkovitosti zgrada počevši od najjednostavnijeg, a to je smanjenje potrošnje energije u sezoni grijanja/hlađenja što izravno dovodi do manjih energetskih troškova. Osim toga, povećanjem energetske učinkovitosti povećava se životni vijek i financijska vrijednost zgrade, poboljšavaju se radni uvjeti, ali i kroz uštede u energiji otvara se prostor za ulaganje financijskih sredstava u inovacije i razvoj.

Sustavnim ulaganjima u energetsku učinkovitost, ulaganjem u inovativne tehnologije za upravljanje potrošnjom energije javni sektor može služiti kao pozitivan primjer društvu kako povećati energetsku učinkovitost i odgovorno koristiti energiju.

Unatoč pozitivnim efektima koji proizlaze iz veće energetske učinkovitosti zgrada, financijska situacija i nedovoljna informiranost korisnika zgrada javnog sektora dovode do toga da za brojne zgrade javnog sektora nisu poznata energetska svojstva, a time vlasnici/korisnici zgrade nemaju jasan uvid u energetska svojstva zgrade i ne koriste mogućnosti koje se pružaju kroz energetsku obnovu javnih zgrada. Postojeći sustav obnove zgrada javnog sektora usmjeren je na korisnike/upravitelje zgrada javnog sektora, oni su ti koji moraju identificirati koliko su energetski učinkoviti i odlučiti se za prijavu u programe za energetsku obnovu zgrada javnog sektora. Nakon prijave korisnika zgrada u takve programe obnove, tijelo zaduženo za upravljanje potrošnjom energije u zgradama javnog sektora odlučuje koje su zgrade od prijavljenih najbolje za uključivanje u program energetske obnove. Međutim, marginalizacija ovog pitanja, nedostatak i nemogućnost sudjelovanja u sufinanciranju programa obnove brojne korisnike zgrada javnog sektora sprječava u poduzimanju prvog koraka.

Kako bi se ostvarila veća energetska učinkovitost u javnom sektoru nužna je sinergija svih dionika u procesu. Tijelo zaduženo za praćenje i upravljanje energetskom učinkovitosti u javnom sektoru mora preuzeti inicijativu i u punom smislu koordinirati korisnike zgrada javnog sektora, posebice onih zgrada s najlošijim energetskim svojstvima te ih uključiti u programe energetske obnove zgrada javnog sektora. Kako omogućiti tijelu zaduženom za upravljanje i praćenje potrošnje energije u javnom sektoru da identificira zgrade javnog sektora s najlošijim energetskim svojstvima, ali da pri tome i korisnici zgrada javnog sektora također dobiju informaciju o energetskom stanju zgrade, bila je nit vodilja prilikom provođenja ovog istraživanja.

Kao rješenje danog problema nametnulo se poboljšanje postojećeg sustava upravljanja i nadzora potrošnje energije u zgradama javnog sektora. Tijelo zaduženo za upravljanje i praćenje potrošnje energije u javnom sektoru svoju zadaću obavlja kroz *Informacijski sustav za gospodarenje energijom – ISGE*, dok su korisnici zgrada javnog sektora u isti sustav dužni periodično unositi podatke o pojedinoj zgradi javnog sektora. ISGE sustav identificiran je kao platforma koja bi nadogradnjom svojih značajki mogla postati inteligentna platforma koja može pomoći u povećanju energetske učinkovitosti zgrada javnog sektora.

Podaci o zgradama javnog sektora za potrebe provedbe ovog istraživanja prikupljeni su iz ISGE sustava. Preuzeti su podaci o svim dostupnim zgradama javnog sektora, odnosno podaci o ukupno 17000 zgrada javnog sektora.

Nakon identificiranja prepreka u ostvarenju veće energetske učinkovitosti u javnom sektoru nametnula su se brojna istraživačka pitanja:

- Koliko je fond zgrada javnog sektora uistinu energetski učinkovit? Za koliko je zgrada javnog sektora poznat energetski razred? Postoji li značajno odstupanje između stvarne potrošnje energije zgrada javnog sektora u Republici Hrvatskoj i procijenjene potrošnje prema energetskim certifikatima zgrada javnog sektora? Ako odstupanje postoji, kako smanjiti odstupanja u predviđanju potrošnje energije u zgradama javnog sektora pomoću metoda strojnog učenja?

- Kako identificirati energetski neučinkovite zgrade unatoč nepostojanju energetskog certifikata na temelju podataka dostupnih u ISGE sustavu?

- Koji su glavni prediktori potrošnje energije zgrada javnog sektora koji mogu poslužiti donositeljima odluka o mjerama i ulaganjima u energetsku obnovu javnog sektora?

Postavljena istraživačka pitanja okosnica su ove doktorske disertacije i kroz odgovor na njih želi se dati doprinos povećanju energetske učinkovitosti u zgradama javnog sektora kroz analizu uspješnosti postojećih modela te predlaganje modela koji će omogućiti prepoznavanje energetski neučinkovitih zgrada.

1.2. Cilj istraživanja

Cilj je doktorske disertacije istražiti energetsku učinkovitost zgrada javnog sektora u Republici Hrvatskoj, utvrditi postoje li odstupanja u potrošnji stvarne i proračunske količine energije u zgradama te predložiti poboljšanje postojećeg ISGE sustava implementacijom modela za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji primarne energije.

Model predložen u ovoj doktorskoj disertaciji temelji se na umjetnim neuronskim mrežama kao metodi strojnog učenja. Svoju funkcionalnost i korisnost predloženi model može dokazati kroz nekoliko područja. Model može služiti prvenstveno kao potpora pri donošenju odluka o ulaganju u energetsku obnovu, kako korisnicima zgrada javnog sektora, tako i provoditeljima energetskih obnova čime bi se doprinijelo boljoj alokaciji financijskih resursa i procjeni ušteda koje proizlaze iz procesa energetske obnove javnog sektora u Republici Hrvatskoj. Korisnik zgrade javnog sektora može dobiti važne i korisne informacije kroz uvid o tome koliko je zgrada koju koristi učinkovita, što najviše utječe na energetske performanse zgrade, ali može dobiti i podlogu za izradu akcijskih planova energetske obnove. Tijelo zaduženo za provođenje programa energetskih obnova zgrada javnog sektora imalo bi jasan uvid u energetsku učinkovitost svih zgrada javnog sektora neovisno o postojanju energetskog certifikata za zgradu. Omogućilo bi se identificiranje zgrada koje imaju velike gubitke energije, a tijelo za provođenje programa energetskih obnova zgrada javnog sektora moglo bi preuzeti inicijativu i takve zgrade prioritetno uključiti u programe energetske obnove čime bi se ostvarile znatne financijske uštede, ali i doprinijelo bržem ostvarenju preuzetih obveza Republike Hrvatske vezanih uz povećanje energetske učinkovitosti do 2030. godine.

Uporaba takvog modela pokazala bi proaktivnost, otvorenost javnog sektora za nova rješenja i promjene te inovaciju postojećeg sustava za upravljanje energijom. Posljednji važan segment odnosi se na educiranje šire javnosti o važnosti energetske učinkovitosti, ali i jačanje institucionalne uloge države i tijela zaduženih za poboljšanje energetske učinkovitosti. Uvođenjem promjena javni sektor svojim primjerom može utjecati na podizanje svijesti o važnosti energetske učinkovitosti i sustavnog upravljanja energijom.

1.3. Struktura rada

Doktorska disertacija može se podijeliti na dva glavna dijela: teorijski i empirijski dio. Kroz šest glavnih poglavlja istražila se energetska učinkovitost zgrada javnog sektora u Republici Hrvatskoj, odgovorilo se na postavljena istraživačka pitanja, predložen je model za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji energije s ciljem poboljšanja postojećeg sustava upravljanja energijom u zgradama javnog sektora te su dane preporuke za dionike. Struktura poglavlja je sljedeća:

U *Uvodnom* dijelu prikazan je istraživački problem, ciljevi rada te istraživačka pitanja. O teorijskim aspektima energetske učinkovitosti, odstupanjima između proračunske i stvarno potrošne količine energije u zgradama javnog sektora te o ulozi poduzetničkog djelovanja u javnom sektoru bavi se drugo poglavlje nazvano *Teorijska podloga*. U poglavlju *Metodologija istraživanja* prikazan je metodološki okvir ove doktorske disertacije, proces pripreme podataka korištenih u ovom istraživanju te su postavljene glavne hipoteze rada. Poglavlje *Opis istraživanja i rezultati* istraživanja može se podijeliti na dva dijela, u prvom dijelu istražio se fenomen odstupanja između proračunske i stvarno potrošene količine energije u zgradama javnog sektora te su se profilirale skupine zgrada ovisno o magnitudi odstupanja u potrošnji energije. Nakon toga uslijedio je postupak izrade modela strojnog učenja za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji primarne energije. Opisan je proces predprocesiranja podataka, selekcije varijabli, treniranje i testiranje modela za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji primarne energije te su identificirani najznačajniji prediktori predloženog modela. U poglavlju *Rasprava* analizirani su dobiveni rezultati istraživanja, ograničenja provedenog istraživanja i dane su preporuke za provoditelje programa energetske učinkovitosti te preporuke za korisnike zgrada javnog sektora. Sinteza doktorske disertacije napravljena je u poglavlju *Zaključak*.

2. TEORIJSKA PODLOGA

Energija je u okruženju prisutna u njenim izvornim i transformiranim oblicima. Podjela po izvornosti najpoznatija je podjela energije, pri čemu se razlikuju obnovljivi i neobnovljivi izvori energije. U obnovljive izvore energije ubraja se sunčeva energija, energija vjetra, energija vode, geotermalna energiju, biomasa i bioplin, odnosno izvori energije koji se neprestano regeneriraju u prirodi. Neobnovljivi izvori energije također se crpe iz prirode, ali za razliku od obnovljivih izvora oni se ne mogu regenerirati i količinski su ograničeni. Energetska politika gotovo svih gospodarskih sustava u najvećoj mjeri ovisna je o neobnovljivim izvorima energije. Pretjerana eksploatacija ugljena, nafte i prirodnog plina dovela je do njihovog značajnog smanjenja, a time i do neodrživosti postojećih energetskih politika temeljenih na fosilnim gorivima. Osim toga, izgaranjem fosilnih goriva dolazi do emisije CO_2 u zemljinu atmosferu što predstavlja značajan ekološki problem.

Međutim, energija i njena transformacija u uporabni oblik omogućila je ekonomski i društveni razvoj čovječanstva. Sve važne prekretnice u razvoju čovječanstva vezane su uz mogućnost korištenja energije čime su se promijenili i dotadašnji načini poslovanja, proizvodnje, prometa, ali posljedično je došlo i do sve veće potrošnje i ovisnosti o energiji, snažne eksploatacije prirodnih resursa i u potpunosti je promijenjena klimatska slika zemlje.

2.1. Potrošnja energije i energetska učinkovitost

Prilikom praćenja potrošnje energije razlikuju se dvije kategorije: primarna i neposredna (finalna) potrošnja energije. Primarna potrošnja energije označava potrošnju one energije koja je u svom „sirovom“ obliku ušla u pojedini energetski sustav (Ritchie i Roser, 2020). Potrošnja energije krajnjih korisnika predstavlja neposrednu (finalnu) potrošnju energije (Eurostat, n.d.).

Krajnjim korisnicima smatraju se industrija, transport, kućanstva, komercijalni sektor i poljoprivreda (Eurostat, n.d.). Neposredna potrošnja energije isključuje potrošnju samog energetskog sektora i gubitke koji nastaju tijekom transformacije i distribucije energije (Eurostat, 2021).

Od industrijske revolucije do danas potrošnja primarne energije u rastućoj je putanji. Na slici 1 prikazana je globalna potrošnja ukupne primarne energije u razdoblju od 1800. do 2019. godine.

Slika 1 Ukupna potrošnja primarne energije u svijetu

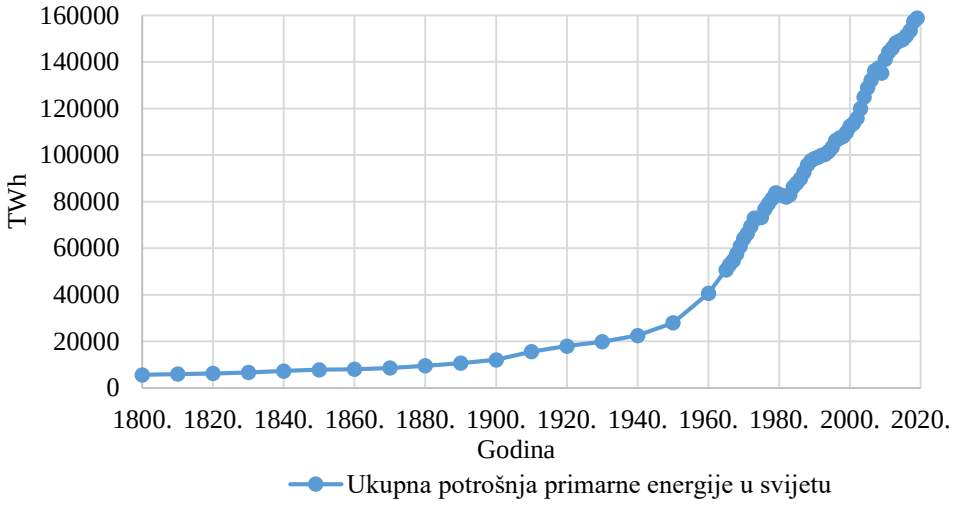

Izvor: Izrada autora na temelju podataka Ritchie i Roser (2020) - "Energy". Objavljeno na OurWorldInData.org. Podaci su preuzeti s: 'https://ourworldindata.org/energy'

Ukupna potrošnja primarne energije 1800. godine iznosila je 5653 TWh pri čemu je najveći udio u potrošnji zauzimala potrošnja tradicionalne biomase, odnosno 5556 TWh dok je potrošnja ugljena iznosila zanemarivih 97 TWh. U usporedbi, 2019. godine ukupna potrošnja primarne energije iznosila je 158839 TWh od čega je najzastupljenija potrošnja nafte koja je iznosila 53620 TWh. U razdoblju od 1965. do 2000. godine najveću potrošnju primarne energije ostvarile su Sjeverna Amerika i Europa dok 2000. godine primat u potrošnji primarne energije zauzima azijski kontinent (slika 2).

Slika 2 Potrošnja primarne energije prema geografskim regijama

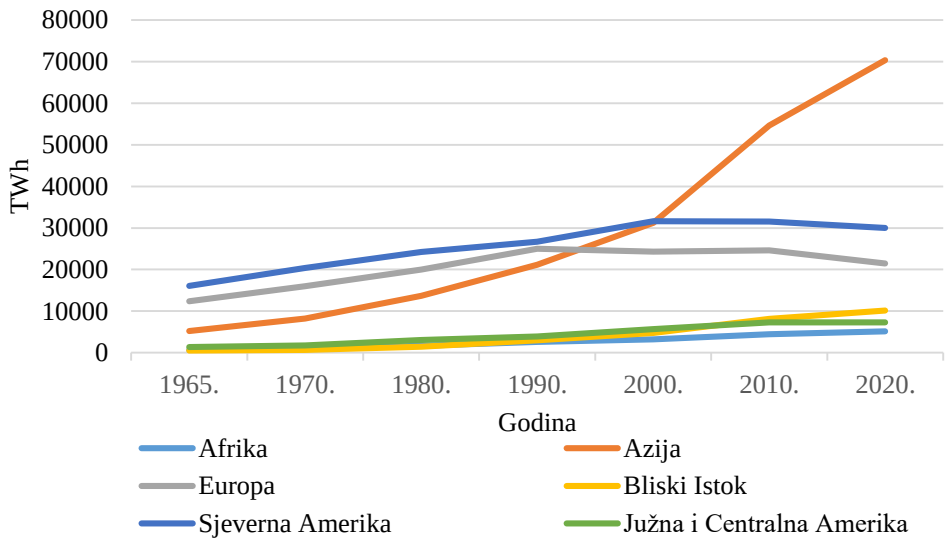

Izvor: Izrada autora na temelju podataka Statistical Review of World Energy (2021). Podaci preuzeti s: https://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy.html

Kako je ranije navedeno, potrošnja krajnjih korisnika naziva se neposredna (finalna) potrošnja. Na globalnoj razini industrijski sektor generira najveću potrošnju energije. Industrijski sektor uključuje postrojenja i opremu koja se koristi za proizvodnju, poljoprivredu, rudarstvo i građevinarstvo (U.S. Energy Information Administration (EIA), 2021).

Sljedeći je prometni sektor koji obuhvaća vozila za prijevoz ljudi ili robe (cestovni, željeznički, pomorski, zračni i ostali promet). Potrošnja energije u prometu odnosi se na svu prometnu djelatnost bez obzira na gospodarski sektor kojem doprinosi (U.S. Energy Information Administration (EIA), 2021). Nakon čega slijedi potrošnja energije u sektoru kućanstva te komercijalni i javni sektor u koji je uključena potrošnja trgovina, ureda, obrazovnih i zdravstvenih institucija.

Potrošnja neposredne energije na svjetskoj razini u razdoblju od 1990. do 2018. godine prikazana je na slici 3.

Slika 3 Svjetska neposredna potrošnja energije po sektorima u razdoblju od 1990. - 2018.

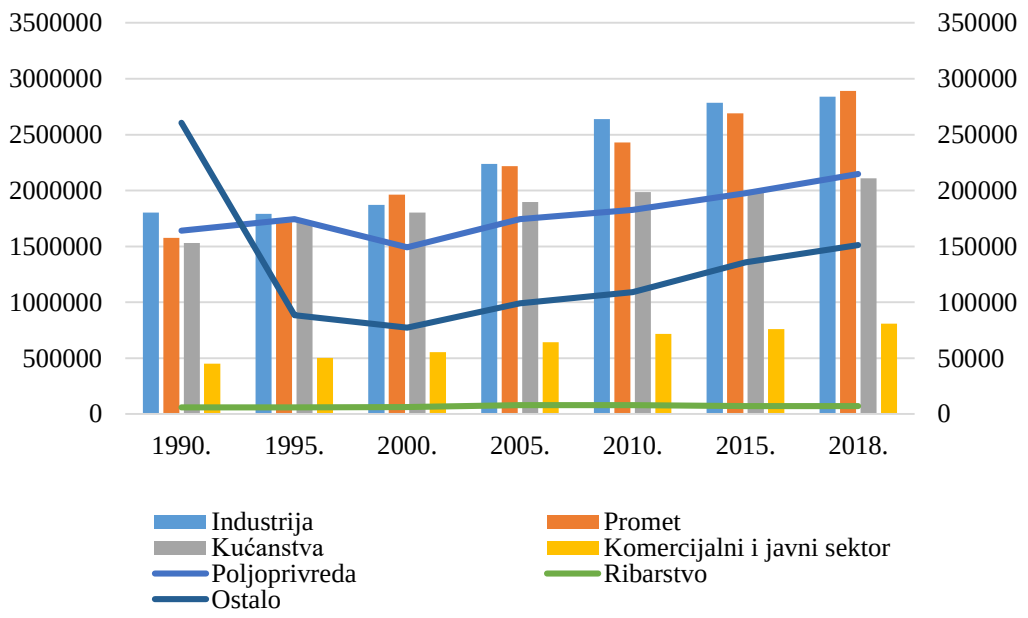

Izvor: Izrada autora na temelju podataka IEA (2021). Podaci preuzeti s: https://www.iea.org/data-and-statistics?country=EU28&fuel=Energy%20consumption&indicator=TFCShareBySector

Potrošnja primarne i neposredne potrošnje u konstantnom je rastu, a oscilacije cijena na tržištima energenata imaju snažan utjecaj na ekonomski rast i razvoj brojnih zemalja.

2.1.1. Potrošnja energije i teorije ekonomskog rasta

Kontinuirano povećanje proizvodnih kapaciteta, proizvodnje roba i usluga, odnosno ekonomski rast cilj je svake zemlje. Ovisno o ekonomskoj teoriji, kao glavne determinante ekonomskog rasta ističu se zemlja, rad, kapital, tehnološki napredak i znanje. Ulogu energije u ekonomskom rastu s aspekta ekonomske teorije dubinski su istražili Jakovac i Vlahinić Lenz (2015). Ovi autori navode kako klasična teorija ekonomskog rasta energiju ne prepoznaje kao izravan faktor proizvodnje. Energija je uključena neposredno preko zemlje kao ključnog faktora proizvodnje. Zemlja, prirodni resursi i izvori energije isključeni su iz faktora proizvodnje i u neoklasičnoj teoriji ekonomskog rasta. Prema neoklasičnoj teoriji ekonomskog rasta kapital i rad svrstavaju se u primarne faktore proizvodnje dok su materijali i sirovine smatrani intermedijarnim faktorima i pridavana im je samo indirektna važnost.

Doprinos u istraživanju uloge energije dala je *Institucionalna ekonomija* kroz istraživanje uloge institucionalnih struktura na učinkovito korištenje energije te na razvoj i implementaciju energetski učinkovitih tehnologija**.** Uloga institucija značajna je u energetskom sektoru iz razloga što je povezanost između energetskih resursa, energetske politike i ekonomskog rasta u velikoj mjeri određena ulogom institucija. Energija se ističe kao najvažniji primarni proizvodni faktor u ekološkoj ekonomiji, prema kojoj raspoloživost, odnosno potrošnja energije potiče ekonomski rast (Jakovac i Vlahinić Lenz, 2015). *Evolucijska ekonomija* usmjerena je na inovacije, procese koji unose konstantne promjene u gospodarstvo utječući na sve dionike kako gospodarske subjekte tako i institucije. U ovoj teoriji „*energetska infrastruktura promatra se kao složen i interaktivan sustav socijalnih, ekonomskih i političkih institucija unutar kojeg međuzavisnost energije i ekonomskog rasta te razvoj novih energetski učinkovitih tehnologija moraju biti shvaćeni u širem socio-ekonomsko-ekološkom kontekstu*“ (citiran Ockwell (2008., str. 4603) u radu Jakovac i Vlahinić Lenz, 2015).

Važnost i uloga energije u ekonomskom razvoju neupitna je. Predmet je istraživačkog interesa u ovom području kauzalnost odnosa između potrošnje energije i ekonomskog rasta. Unatoč brojnim istraživanjima, ne postoji jedinstveni konsenzus o kauzalnosti veze potrošnje i ekonomskog rasta.

Prema Fatur Šikić (2020) rezultati empirijskih istraživanja o smjeru kauzalne veze između potrošnje energije i ekonomskog rasta mogu se grupirati u glavne četiri hipoteze:

- *hipoteza rasta* koja ukazuje na postojanje snažne jednosmjerne veze između potrošnje energije i ekonomskog rasta,

- *hipoteza očuvanja* koja implicira jednosmjernu vezu između ekonomskog rasta i potrošnje energije, odnosno ekonomski rast uzrokuje potrošnju energije,
- *hipoteza povratne veze* koja implicira na postojanje dvosmjerne veze između potrošnje i ekonomskog rasta, što bi značilo da svaka promjena u potrošnji energije utječe na ekonomski rast i obrnuto,
- *hipoteza neutralnosti* koja implicira na međusobnu neovisnost između potrošnje energije i ekonomskog rasta, odnosno povećanje ili smanjenje potrošnje energije nema utjecaja na ekonomski rast.

Uzroci oprečnosti u istraživanjima na temelju kojih su generirane prethodno navedene hipoteze o kauzalnosti veze između ekonomskog rasta i potrošnje energije prema Fatur Šikić (2020) su:

- različite statističke metode *(vektorski autoregresijski model, Grangerov test kauzalnosti, multivarijantne metode, panel analiza podataka, testovi stacionarnosti i kointegracije),*
- obuhvat podataka (*agregirane potrošnje energije i ekonomskog rasta, potrošnje obnovljivih i neobnovljivih izvora energije i ekonomskog rasta*),
- ispitivani vremenski okvir podataka *(kratkoročni i dugoročni period),*
- specifičnosti analiziranih zemalja i regija *(društveno uređenje, razina institucionalnog razvoja, energetske i ekonomske politike).*

Poznavanje smjera kauzalne veze važno je radi implementacije i provedbe ekonomski učinkovitih energetskih politika i predviđanja njihovih utjecaja na potrošnju energije i na ekonomski rast (Jakovac, 2018). Kako bi se prikazao utjecaj energije na ekonomiju u cjelini te na pojedine sektore, razvijeni su pokazatelji koji stavljaju u odnos ekonomske i energetske pokazatelje. Uloga energetskih pokazatelja višestruka je (Enerdata, 2020): omogućavaju razumijevanje trendova u potrošnji energije i energetskoj učinkovitosti, daju informacije o prodoru opreme za krajnju upotrebu i energetski učinkovite tehnologije na tržište, omogućavaju usporedivost među zemljama i postavljanje referentnih vrijednosti energetske učinkovitosti, omogućavaju postavljanje i praćenje ciljeva na nacionalnoj i međunarodnoj razini u području energetske učinkovitosti i smanjenju emisije CO_2, omogućavaju vrednovanje politika i programa energetske učinkovitosti te služe za poboljšanje postojećih tehničko-ekonomskih modela za predviđanje potražnje za energijom. Energetski pokazatelji mogu se grupirati prema svojoj ulozi, kompleksnosti i mogućnosti objašnjenja. Pokazatelji energetske efikasnosti prikazani su u tablici 1.

Tablica 1 Pokazatelji energetske učinkovitosti

Pokazatelji za praćenje trendova u energetskoj učinkovitosti i smanjenju CO_2 po zemljama	
Opisni pokazatelji	**Pokazatelji objašnjenja**
Opisuju ukupne trendove energetske učinkovitosti s makro-ekonomskog gledišta; opisni indikatori izračunavaju se iz redovnih službenih ekonomskih i energetskih statistika kao izravan omjer potrošnje energije i makro-ekonomske varijable.	Objašnjavaju trendove zabilježene u opisnim indikatorima; indikatori problema mogu se oslanjati na redovne statistike, ali se također mogu i procijeniti ili poticati iz anketa. Intenziteti postojanih struktura, Indeks napretka energetske učinkovitosti (ODEX) ili uštede energije indikatori su objašnjenja.
Pokazatelj energije/ugljika - povezuju potrošnju energije (mjerenu u jedinicama energije) ili emisiju CO_2 s pokazateljem aktivnosti izraženim u monetarnim jedinicama. **Tehničko-ekonomski omjeri ili jedinična potrošnja/jedinična emisija CO_2 -** povezuju potrošnju energije ili emisiju CO_2 s pokazateljima aktivnosti izraženim u fizičkim mjerilima. **Indeks napretka energetske učinkovitosti – ODEX –** definiran na razini sektora (industrije, prometa, kućanstava) ili na razini gospodarstva. Indeks se dobiva agregiranjem promjena jedinične potrošnje podsektora ili na razini krajnjeg potrošača, promatranog tijekom određenog razdoblja ili krajnjom potrošnjom, praćenom tijekom određenog razdoblja. **Uštede energije/CO_2** - varijacije ODEX-a, u smislu količine uštede energije (izražene u Mtoe) ili uštede CO_2 (izražena u Mt), u odnosu na situaciju bez napretka energetske učinkovitosti.	
Pokazatelji za usporedbu razine "učinkovitosti" energetske učinkovitosti među zemljama	
Prilagođeni pokazatelji	**Referentna vrijednost (engl. *Benchmark)* ili ciljni pokazatelj**
Za strukturalne razlike među zemljama kako bi se omogućila njihova što točnija usporedba.	Pokazuje razliku između stvarne vrijednosti i ciljne vrijednosti nekog od pokazatelja za pojedinu zemlju. Razlika između stvarne vrijednosti pokazatelja i njegove ciljne vrijednosti ukazuje na ostvarivi potencijal za poboljšanje energetske učinkovitosti.
Pokazatelji difuzije za mjerenje difuzije (tj. prodora na tržište) učinkovitih tehnologija i praksi	
Pokazatelji koji služe za dopunu procjene sektorskih trendova energetske učinkovitosti.	
Prodor učinkovitih tehnologija na tržište, npr. broj prodanih učinkovitih žarulja, % oznake A u novim prodajama električnih uređaja. **Difuzija/širenje energetski učinkovitih običaja**, npr. % putnika u javnom prijevozu i putnika na ne-motornim sredstvima, % prometa roba željeznicom i kombinirani željezničko-cestovni promet, % učinkovitih procesa u industriji. **Prodor na tržište obnovljivih za krajnju uporabu**, npr. broj solarnih grijača za vodu, % grijaćih bojlera na drva.	

Izvor: Izrada autora prema Božić i suradnici (2009). Indikatori energetske učinkovitosti. Journal of Energy: Energija, 58(5)

Pokazatelj energetske intenzivnosti ističe se kao jedan od najvažnijih energetskih pokazatelja (Gelo, 2010). Energetska intenzivnost stavlja u odnos potrošnju energije *(Pe)* izraženu u odgovarajućim energetskim jedinicama i dohodak zemlje *(Y)* izražen u monetarnim jedinicama.

$$EI=\frac{Pe}{Y} \tag{1}$$

Kao takav koristan je pokazatelj nositeljima energetske i ekonomske politike o poboljšanju energetske efikasnosti nacionalnog gospodarstva (Gelo, 2010). Drugim riječima, energetska intenzivnosti pokazatelj je promjena u korištenju energije po jediničnom proizvodu ili usluga te promjena uspješnosti u ostvarenju tržišne vrijednosti proizvoda ili usluga (Centar za praćenje poslovanja energetskog sektora i investicija, n.d.). Visoki energetski intenzitet ukazuje na visoku cijenu ili trošak pretvaranja energije u Bruto domaći proizvod (BDP), dok niži energetski intenzitet ukazuje na nižu cijenu ili trošak pretvaranja energije u BDP.

Koristi pokazatelja energetske intenzivnosti višestruke su jer ukazuju na promjene u intenzitetu potrošnje energije, ali i pomažu u podizanju svijesti javnosti o tome kako i zašto se intenzitet energije promijenio tijekom godina. Ujedno je i važan faktor u analizi politika i programa, odnosno njihovog utjecaja na energetsku intenzivnost te omogućava razumijevanje uloge povećanja učinkovitosti na energetskim tržištima. Razina energetske intenzivnosti i njezin trend kretanja ovisi o brojnim faktorima. Prema Geli (2010) najznačajniji faktori su: klimatske razlike, udaljenosti između većih gradskih središta, razlike u strukturi industrijske proizvodnje, uloga visoke tehnologije, socio-ekonomske okolnosti, razina proizvodnje, struktura gospodarstva, struktura potrošnje energije, dohodak po jedinici potrošene energije i supstituciji između energije i ostalih ulaznih vrijednosti (engl. *inputa*) kao što su kapital i rad u proizvodnoj funkciji.

Pokazatelj energetskog intenziteta ukazuje i na razinu energetske učinkovitosti. Pokazatelj energetskog intenziteta obrnuto je proporcionalan energetskoj učinkovitosti. Povećanjem energetske učinkovitosti smanjuje se energetski intenzitet, odnosno potrebno je manje energije za proizvodnju jedinice BDP-a, i obrnuto (Gelo, 2010).

2.1.2. Potrošnja energije i politike Europske unije

Kroz stoljeća vidljiv je trend rastuće potrošnje energije, dominacija određenih izvora energije od ugljena do naftne ere te velika ovisnost gospodarstva, ali i društva u cjelini o energiji. Kako bi se osigurala energetska stabilnost, dostupnost čiste i jeftine energije, brojne zemlje donose strategije i planove za prelazak na niskougljičnu održivu ekonomiju. Na razini Europske unije (EU) 2015. godine donesen je dokument pod nazivom „*Strategija energetske unije*“ kao odgovor na 3 ključna izazova s kojima se Europa suočava:

- *klimatske promjene*: smanjenje emisije CO_2 i postizanje klimatske neutralnosti do 2050.,
- *energetska ovisnost:* osiguranje energetske stabilnosti i smanjenje uvoza energije s vanjskih tržišta,
- *infrastruktura:* modernizacija energetskog tržišta i energetske infrastrukture te osiguranje usklađenosti nacionalnih cijena energije (Vijeće Europske unije, 2021).

Strategijom energetske unije nastoji se osigurati dostupna, čista, stabilna energija za sve Europljane te stvoriti održivi energetski sektor koji potiče rast, inovacije i radna mjesta. Energetska unija obuhvaća djelovanje na pet ključnih, međusobno povezanih područja:

- energetska sigurnost, solidarnost i povjerenje,
- jedinstveno EU energetsko tržište,
- energetska učinkovitost,
- klimatske promjene i dekarbonizacija gospodarstva,
- istraživanje, inovacije, konkurentnost (Europska komisija, n.d.).

Za EU posebno je važno pitanje energetske sigurnosti. Proizvodnja primarne energije unutar EU nije dovoljna da bi se zadovoljila rastuća potražnja za energijom i kao takva je najveći uvoznik energije, posebno nafte i prirodnog plina. U 2018. godini u EU gotovo 58 % dostupne energije došlo je iz uvoza, a Rusija je glavni dobavljač prirodnog plina, sirove nafte te kamenog ugljena (Eurostat, 2020). Oscilacije na tržištu nafte i prirodnog plina često su se negativno odražavale na gospodarski sustav brojnih zemalja članica EU. Kako bi se umanjio utjecaj vanjskih disruptora i potencijalni poremećaji u opskrbi prirodnog plina te se osigurao pravodoban odgovor stvoreni su zajednički standardi i pokazatelji za mjerenje ozbiljnih prijetnji, ali i planovi u kojima se definiraju količine plina potrebne za opskrbu kućanstava i ostalih potrošača zemalja članica (Europska komisija, n.d.).

Prepoznata je i važnost diversifikacije opskrbnih puteva, otvaranje novih puteva opskrbe te terminala opskrbe kako bi se smanjila ovisnost EU o jednom dobavljaču prirodnog plina i drugih izvora primarne energije (Europska komisija, n.d.). Međutim, važan faktor za smanjenje vanjskog utjecaja na energetsku sliku EU je i slobodan protok energije kroz EU putem odgovarajuće infrastrukture bez tehničkih ili regulatornih prepreka, odnosno stvaranje jedinstvenog europskog energetskog tržišta. Liderstvo u proizvodnji energije iz obnovljivih izvora te ispunjenje *Pariškog sporazuma o klimatskim promjenama* u pogledu dekarbonizacija gospodarstva također je važan aspekt energetske unije energije (Europska komisija, n.d.).

EU potiče istraživanje i razvoj tehnologija koje će pokrenuti energetsku tranziciju i na taj način pridonijeti konkurentnosti i stabilnosti. Smanjenje potrošnje energije, posebno iz neobnovljivih izvora, smanjenje troškova energije, smanjenje emisije stakleničkih plinova te prijelaz na čistu energiju dugotrajan je i kompleksan proces uvjetovan brojnim faktorima (Europska komisija, n.d.). U procesu prelaska ka nisko ugljičnoj ekonomiji potrebno je pomiriti postojeće potrebe za energijom, ali ujedno očuvati zalihe fosilnih goriva i smanjiti emisiju stakleničkih plinova, a energetska učinkovitost ističe se kao najjeftiniji i najefikasniji alat za to i kao takva važan je dio Europske energetske unije.

2.2. Energetska učinkovitost

Energetska učinkovitost definira se kao korištenje manje energije za obavljanje istog posla, odnosno uklanjanje energetskog rasipanja (Environmental and Energy Study Institute, n.d.).
U Republici Hrvatskoj *Zakonom o energetskoj učinkovitosti* (NN 127/14, NN 116/18, NN 25/20, NN 41/21) definira se kao *„odnos između ostvarenog korisnog učinka i energije potrošene za ostvarenje tog učinka“*.

Međutim, važno je razlučiti termin energetske učinkovitosti od termina štednje ili uzdržavanja od trošenja energije. Ušteda energije koja je proizašla odricanjem od potrošnje označava uštedu u potrošnji energije koja je ostvarena kroz nižu kvalitetu energetskih usluga npr. smanjivanje razine termostata, postavljanje ograničenja potrošnje na uređajima, odnosno odricanjem od potrošnje energije (Gelo, 2010; Herring, 2006). Energetska učinkovitost omogućava upravo suprotno. Ne podrazumijeva odricanje od potrošnje, već omogućavanje jednake kvalitete procesa ili usluga, ali uz manje utrošene energije. Drugim riječima, krajnji korisnik dobiva jednaku kvalitetu proizvoda ili usluga uz manji utrošak energije.

Ulaganjem u energetsku učinkovitost ostvaruju se višestruke koristi (International Energy Agency, 2014):

- smanjena potrošnja energije i poboljšana efikasnost u upravljanju potrošnjom energije ima pozitivan utjecaj na rast BDP-a,
- smanjenje ovisnosti o energentima dovodi do povećanja energetske sigurnosti i smanjuje se ovisnost o uvozu energije,
- smanjenjem izdataka za troškove energije utječe se na proračun javnog sektora, ali također postoji i neizravan utjecaj na javni proračun kroz zaposlenost koja proizlazi iz energetskih investicija i poslovnih aktivnosti do kojih posljedično dolazi,
- povećanje energetske učinkovitosti odražava se i na zdravlje krajnjih korisnika – bolja kvaliteta zraka, kvalitetniji radni prostor, smanjenje energetskog siromaštva,
- smanjenjem korištenja fosilnih goriva izravno se utječe na zaštitu okoliša,
- strateško ulaganje poduzeća koje vodi ka većoj konkurentnosti**,** smanjenju troškova rada i održavanja te poboljšanju radnih uvjeta.

Na razini EU energetska učinkovitost prepoznata je i kao put za brži prelazak na nisko ugljičnu ekonomiju te u sklopu energetskog – klimatskog paketa predstavljenog 2007. godine poznatijeg pod nazivom *20-20-20* postavljen je jasan cilj u tom području: *„povećanje energetske učinkovitosti za 20 % do 2020. godine, odnosno 32,5 % do 2030 godine“*.

Europski paket smjernica za postizanje energetske učinkovitosti, odnosno ostvarenje postavljenog cilja povećanja energetske učinkovitosti za 20 % čine dvije direktive: *Direktiva o energetskoj učinkovitosti* te *Direktiva 2010/31/EU o energetskoj učinkovitosti zgrada* (Centar za praćenje poslovanja energetskog sektora i investicija, n.d.). *Direktivom 2010/31/EU o energetskoj učinkovitosti zgrada* (2010) nastoji se unaprijediti energetska učinkovitosti zgrada u EU i njome su postavljeni minimalni zahtjevi i zajednički okvir za izračun energetske učinkovitosti.

Direktiva o energetskoj učinkovitosti (2012/27/EU) donesena je 2012. godine i njome je definiran predmet, područje primjene, definicije i ciljevi povećanja energetske učinkovitosti na području EU (Direktiva 2012/27/EU o energetskoj učinkovitosti). Uloga i područje primjene Direktive 2012/27/EU o energetskoj učinkovitosti definirana je Člankom 1 koji glasi: *„Ovom se Direktivom uspostavlja zajednički okvir mjera za poticanje energetske učinkovitosti u Uniji kako bi se osiguralo ostvarivanje krovnog cilja povećanja energetske učinkovitosti Unije za 20 % do 2020. i otvorio put daljnjim poboljšanjima energetske učinkovitosti nakon te godine.*

Njome se utvrđuju pravila čija je namjena otklanjanje prepreka na tržištu energije i prevladavanje neefikasnosti tržišta koje ograničavaju učinkovitost u opskrbi energijom i njezinoj uporabi i osigurava utvrđivanje okvirnih nacionalnih ciljeva povećanja energetske učinkovitosti do 2020.“

Glavni je cilj *Direktive o energetskoj učinkovitosti (2012/27/EU)* pružanje jedinstvenog okvira, smjernica i mjera na temelju kojih su države članice obvezne uspostaviti nacionalni cilj povećanja energetske učinkovitosti na temelju potrošnje primarne energije ili krajnje potrošnje energije, uštede primarne ili krajnje energije ili energetskog intenziteta. Zemlje članice slobodne su u kreiranju nacionalnog okvira, mjera za povećanje energetske učinkovitosti ali pri tome obvezne su pratiti sljedeće smjernice (Europska komisija, 2021):

- potrošnja energije u EU u 2020. ne smije biti veća od 1483 Mtoe primarne energije te 1086 Mtoe finalne energije. Izlaskom Velike Britanije revidirao se postojeći cilj za 2020. godinu prema kojem potrošnja primarne energije ne bi trebala biti veća od 1312 Mtoe, a finalna veća od 959 Mtoe,
- nacionalni programi moraju uključiti mjere predviđene Direktivom,
- usvojene mjere za uštedu energije moraju biti skladu s člankom 4. stavkom 1. Direktive 2006/32/EZ[1],
- druge mjere za poticanje energetske učinkovitosti u državama članicama i na razini EU.

Direktiva o energetskoj učinkovitosti (2018/844) sljedbenik je *Direktive o energetskoj učinkovitosti* (2012/27/EU) i njome su revidirani postojeći ciljevi vezani uz potrošnju energije. Energetskom i klimatskom *„Strategijom 2030“* postavljeni su novi ciljevi zemalja članica EU za razdoblje od 2021. do 2030. godine (Centar za praćenje poslovanja energetskog sektora i investicija, n.d.). Ciljevi postavljeni u *Strategiji 2030* su sljedeći:

- smanjene emisija stakleničkih plinova za 40 % u usporedbi s razinama izmjerenim 1990.,
- najmanje 27 % potrošene energije mora biti generirano iz obnovljivih izvora,
- povećanje energetske učinkovitosti do 2030. za barem 32,5 %,
- potrošnja energije u EU u 2030. godini ne bi trebala biti veća od 1273 Mtoe primarne energije te 956 Mtoe finalne energije. Izlaskom Velike Britanije iz EU, planirani je cilj potrošnje energije revidiran i prema njemu potrošnja primarne energije ne bi trebala

[1] Direktiva 2006/32/EZ Europskog parlamenta i Vijeća od 5. travnja 2006. o energetskoj učinkovitosti u krajnjoj potrošnji i energetskim uslugama (https://eur-lex.europa.eu/legal-content/HR/TXT/?uri=CELEX%3A32006L0032)

prelaziti 1128 Mtoe te potrošnja finalne energije ne bi trebala prelaziti 846 Mtoe (Europska komisija, 2021; Centar za praćenje poslovanja energetskog sektora i investicija, n.d.).

Na razini EU, ostvarenje ciljeva u području energetske učinkovitosti prati se kroz potrošnju primarne i finalne energije. Potrošnja primarne energije za 27 zemalja članica EU prikazana je na slici 4.

Slika 4 Potrošnja primarne energije - EU 27

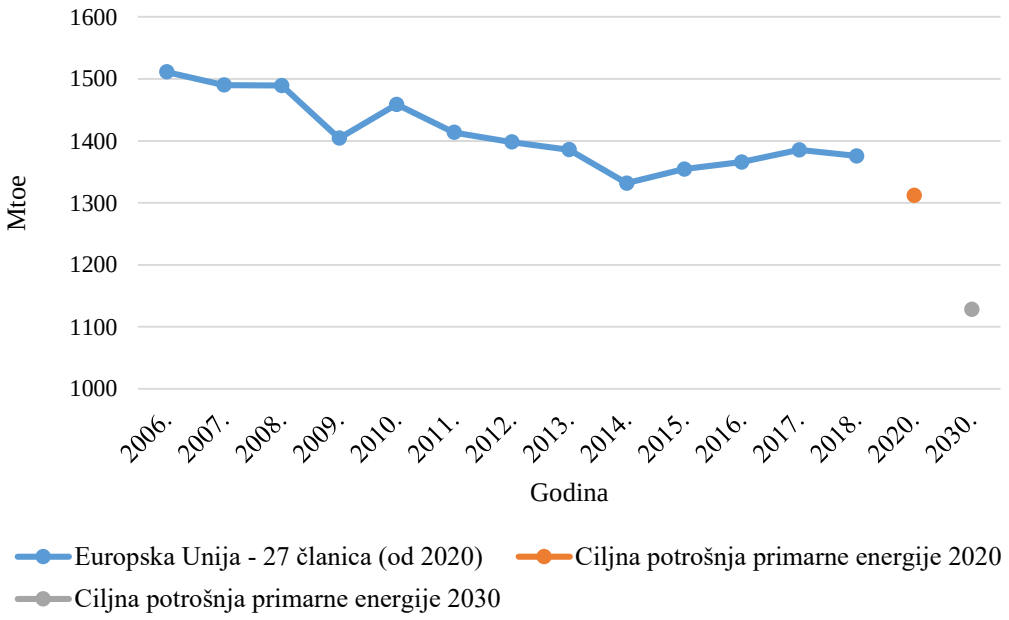

Izvor: Izrada autora na temelju podataka iz baze Eurostat. Preuzeto s: https://ec.europa.eu/eurostat/databrowser/view/NRG_IND_EFF__custom_418976/default/table?lang=en

Iz prikaza je isključena potrošnja primarne energije Velike Britanije u razdoblju od 2006. do 2020. godine. U promatranom razdoblju najveća potrošnja primarne energije ostvarena je 2006. godine i iznosila je 1511,19 Mtoe, odnosno potrošnja primarne energije bila je 15,18 % veća od ciljne potrošnje za 2020. godinu. Pad u potrošnji primarne energije ostvaren je 2009. godine (smanjenje od 5,7 % u odnosu na potrošnju primarne energije ostvarene u 2008. godini, odnosno 7 % u odnosu na 2006. godinu).

U 2010. godini dolazi do rasta potrošnje primarne energije te je sljedeći značajniji pad u potrošnji primarne energije ostvaren 2014. godine (smanjenje od 3,9 % u odnosu na potrošnju primarne energije ostvarene u 2013. godini, odnosno 12 % u odnosu na 2006. godinu). Uočeni značajniji padovi uslijedili su uslijed ekonomske krize i taj se pad u potrošnji primarne energije može povezati sa smanjenim gospodarskim aktivnostima.

Potrošnja primarne energije u 2018. godini iznosila je 1375,66 Mtoe. U usporedbi s ciljnom potrošnjom primarne energije za 2020. godinu uočeno je kako je potrošnja primarne energije ostvarena u 2018. godini za 4,9 % veća od ciljne potrošnje primarne energije dok je u usporedbi s ciljnom potrošnjom za 2030. godinu ona veća za 22 %. Značajnije smanjenje u potrošnji primarne energije zabilježeno je 2019. i 2020. godine.

Potrošnja primarne energije 2019. iznosila je 1353,68 Mtoe i gotovo je dosegnuta ciljna potrošnja za 2020. godinu. Potrošnja primarne energije u 2020. godini iznosila je 1236,49 Mtoe te je u odnosu na ciljnu potrošnju za 2020. godinu, koja je iznosila 1312 Mtoe, došlo do smanjenja potrošnje primarne energije za 5,8 %. U usporedbi s ciljem za 2030. godinu potrošnja primarne energije u 2020. godine bila je veća za 9,6 %.

Finalna potrošnja energije na razini EU (iz prikaza je isključena Velika Britanija) u razdoblju od 2006. do 2020. godine prikazana je na slici 5.

Slika 5 Potrošnja finalne energije – EU 27

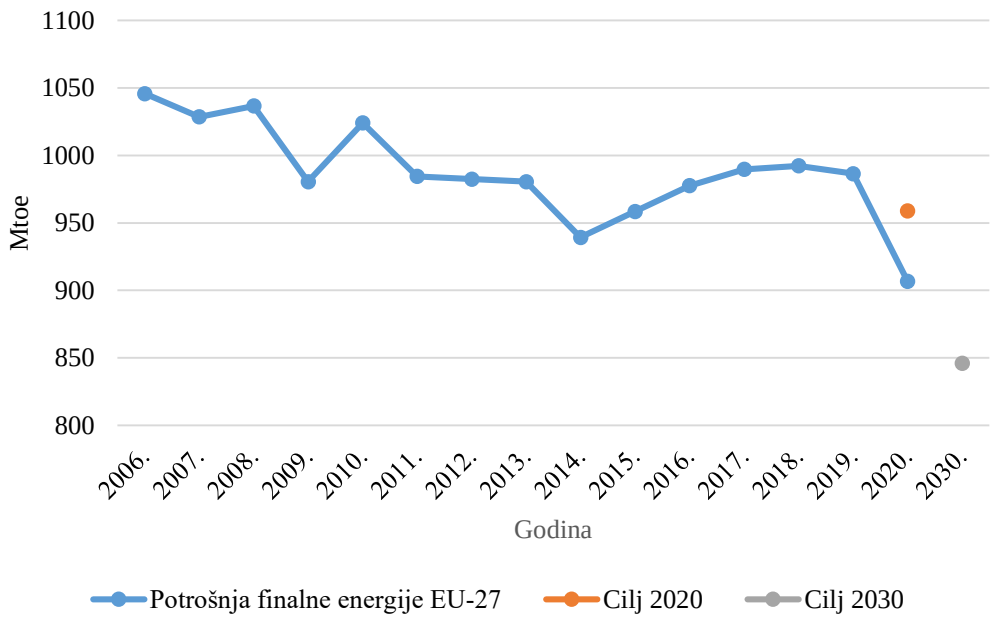

Izvor: Izrada autora na temelju podataka iz baze Eurostat. Preuzeto s: https://ec.europa.eu/eurostat/databrowser/view/NRG_IND_EFF__custom_420951/default/table?lang=en

Na razini EU najveća potrošnja finalne energije ostvarena je u 2006. godini i iznosila je 1046,05 Mtoe, nakon čega dolazi do trenda smanjenja u potrošnji finalne energije. Kao i u potrošnji primarne energije značajno smanjenje u potrošnji finalne energije ostvareno je 2009. godine (pad potrošnje finalne energije iznosio je 5,4 % u odnosu na potrošnju u 2008. godini) te 2014.

godine kad je pad potrošnje u odnosu na 2013. godinu iznosio 4,2 % u odnosu na potrošnju finalne energije u 2013. godini. Nakon 2014. godine potrošnja finalne energije je u rastu. Potrošnja finalne energije u 2018. godini iznosila je 989,46 Mtoe, što je za 3,2 % iznad potrošnje planirane za ciljnu potrošnju u 2020. godini prema kojoj potrošnja finalne energije ne bi smjela biti veća od 959 Mtoe. U odnosu na ciljnu finalnu potrošnju planiranu u mjerama za 2030. godinu potrošnja energije 2018. godine bila je veća za 17 %.

Ciljna je potrošnja finalne energije za 2020. godinu dosegnuta i iznosila je 906,8 Mtoe, odnosno za niža je za 5,4 % od ciljne potrošnje za 2020. godinu. U usporedbi s ciljnom potrošnjom za 2030. godinu, potrošnja energije u 2020. godini viša je za 7,2 %. Ukupna potrošnja primarne i neposredne energije na razini EU bilježi smanjenje i kretanje prema zadanim ciljevima. Zemlje članice EU različitim intenzitetom ostvaruju ciljeve vezane za smanjenje potrošnje energije. U nastavku je prikazana potrošnja primarne energije izražena u Mtoe u razdoblju od 2006. do 2019. godine za zemlje članice EU (tablica 2).

Tablica 2 Potrošnja primarne energije u zemljama članicama EU

Zemlja	2006.	2007.	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2017.	2018.	2019.
Belgija	51,41	50,32	51,13	50,47	54,19	50,3	47,76	49,35	45,67	46,03	49,15	49,14	46,93	49,11
Bugarska	19,85	19,51	19,02	16,91	17,4	18,57	17,83	16,5	17,26	17,96	17,67	18,32	18,37	18,22
Češka	43,49	43,65	42,51	40,16	42,54	40,87	40,38	40,67	38,98	39,44	39,74	40,35	40,39	40,11
Danska	20,84	20,37	19,91	18,91	20,02	18,52	17,82	17,84	16,92	16,9	17,34	17,42	17,4	16,83
Njemačka	332,75	315,79	320,76	299,92	315,15	297,8	301,12	308,29	293,6	295,93	297,63	298,12	292,15	282,71
Estonija	4,92	5,53	5,35	4,74	5,56	5,6	5,42	5,98	5,7	5,34	5,9	5,65	6,06	4,71
Irska	15,12	15,98	15,65	14,9	14,71	13,53	13,7	13,1	13,27	13,96	14,64	14,45	14,67	14,66
Grčka	30,27	30,31	30,48	29,43	27,24	26,65	26,54	23,42	23,29	23,39	23,06	23,24	22,59	24,26
Španjolska	136,22	138,85	133,93	122,92	122,88	122,52	122,9	115,56	113,69	118,04	118,73	125,22	124,59	120,75
Francuska	256,17	252,66	255,4	246,32	254,45	249,11	249,07	250,45	239,82	244,35	239,95	239,22	238,94	235,26
Hrvatska	**9,11**	**9,43**	**9,19**	**8,95**	**8,86**	**8,65**	**8,18**	**8**	**7,6**	**7,96**	**8,05**	**8,33**	**8,18**	**8,21**
Italija	178,95	178,67	176,12	164,08	167,28	162	156,56	152,05	142,66	149,12	147,97	148,95	147,24	145,89
Cipar	2,57	2,7	2,85	2,77	2,68	2,65	2,5	2,18	2,22	2,28	2,43	2,53	2,55	2,54
Latvija	4,66	4,77	4,58	4,43	4,56	4,28	4,44	4,36	4,36	4,27	4,29	4,47	4,69	4,56
Litva	7,89	8,1	8,26	7,82	6,17	5,91	5,98	5,8	5,75	5,79	6,04	6,16	6,37	6,28
Luksemburg	4,69	4,61	4,61	4,34	4,61	4,53	4,42	4,3	4,19	4,14	4,15	4,29	4,46	4,5
Mađarska	25,98	25,36	25,16	23,95	24,62	24,39	23,13	22,41	21,99	23,3	23,65	24,46	24,48	24,57
Malta	0,92	0,95	0,96	0,88	0,93	0,93	0,97	0,87	0,89	0,75	0,71	0,81	0,82	0,87
Nizozemska	69,52	69,37	69,88	67,63	71,72	67,05	66,75	66,21	62,32	63,9	64,89	64,92	64,23	63,46
Austrija	32,62	32,18	32,46	30,64	32,86	31,97	31,67	32,07	30,8	31,65	32,04	32,81	31,8	32,2
Poljska	92,34	91,9	93,09	89,53	96,56	96,55	92,8	93,4	89,49	90,05	94,83	99,1	101	98,13
Portugal	24,04	23,86	23,6	23,63	22,65	22,01	21,04	21,04	20,68	21,65	21,77	22,82	22,65	22,08
Rumunjska	37,53	37,44	37,32	32,65	32,95	33,53	33,26	30,41	30,07	30,75	30,65	32,46	32,57	31,97
Slovenija	7,19	7,28	7,73	6,82	7,03	7,11	6,83	6,65	6,39	6,34	6,55	6,73	6,65	6,52
Slovačka	17,24	16,43	16,99	15,52	16,66	15,97	15,59	15,69	14,83	15,22	15,37	16,15	15,79	15,98
Finska	36,67	36,03	34,52	32,34	35,44	34,2	32,98	31,99	32,67	31,19	32,22	32,09	32,74	32,06
Švedska	47,71	47,41	47,25	43,06	48,34	47,55	47,45	46,44	45,96	43,84	45,35	46,35	47,25	45,78

Izvor: Izrada autora na temelju podataka iz baze Eurostat.
Preuzeto s: https://ec.europa.eu/eurostat/databrowser/view/nrg_ind_eff/default/table?lang=en

Potrošnja primarne energije u Republici Hrvatskoj na najvišoj razini bila je 2007. godine kad je iznosila 9,43 Mtoe. U sljedećim godinama dolazi do kontinuiranog smanjenja potrošnje primarne energije te je 2014. godine zabilježen najsnažniji pad u potrošnji primarne energije koja je tada iznosila 7,6 Mtoe. Od 2014. godine do 2019. godine potrošnja primarne energije bilježi trend laganog rasta, ali ukupna razina potrošnje niža je u odnosu na 2006. godinu. Prosječna promjena u potrošnji primarne energije zemalja članica EU u razdoblju od 2017. do 2019. godine u odnosu na potrošnju u 2020. godine prikazana je slici 6.

Slika 6 Prosječna promjena u potrošnji primarne energije u razdoblju od 2017. do 2019. godine

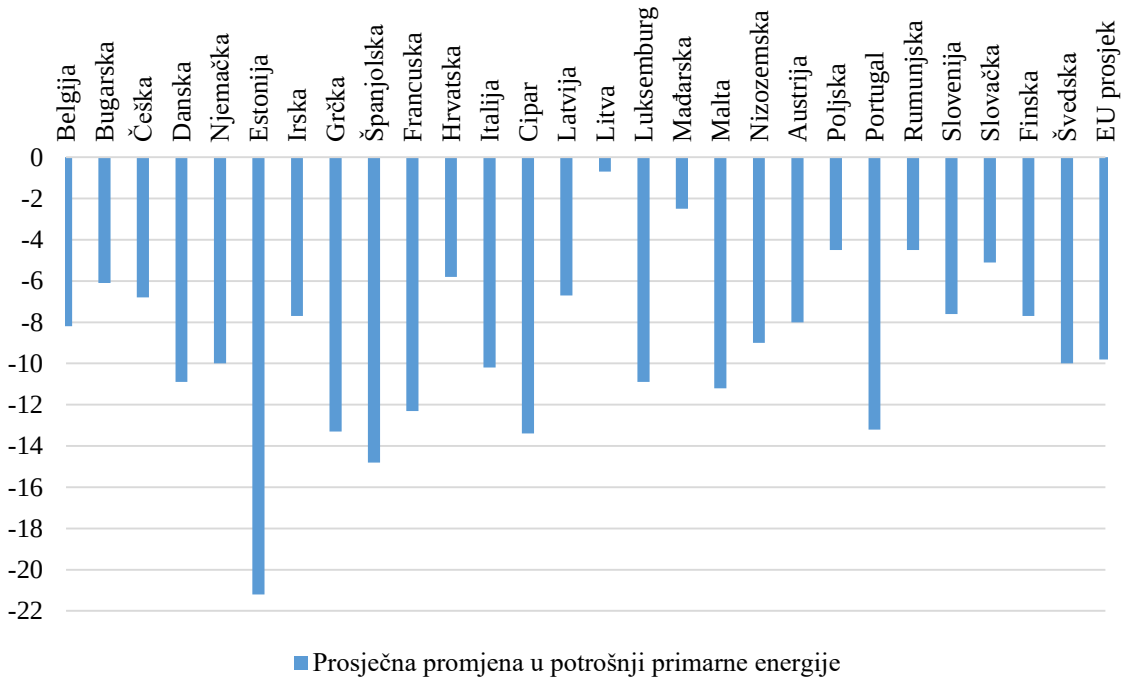

Izvor: Eurostat (2021). Energy saving statistics. Preuzeto s: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Energy_saving_statistics#Country_specific_evolution

Potrošnja primarne energije u 2020. godini u odnosu na prosječnu potrošnju za 2017., 2018. i 2019. godinu niža je u svim zemljama članicama EU. Najveće smanjenje u potrošnji primarne energije ostvareno je u Estoniji (-21,2 %) i Španjolskoj (-14,8 %) dok je najmanje smanjenje potrošnje primarne energije ostvareno u Litvi (-0,7 %), Mađarskoj (-2,5 %) i Rumunjskoj (-4,5 %) (Eurostat, 2021). Republika Hrvatska također bilježi smanjenje potrošnje primarne energije od 9,9 %, dok je prosječno smanjenje u potrošnji primarne energije na razini EU 5,8 %. Kretanje u potrošnji finalne energije slično je potrošnji primarne energije. Potrošnja finalne energije za zemlje članice EU u razdoblju od 2006. do 2019. prikazana je u tablici 3.

Tablica 3 Potrošnja finalne energije u zemljama članicama EU

Zemlja	**2006.**	**2007.**	**2008.**	**2009.**	**2010.**	**2011.**	**2012.**	**2013.**	**2014.**	**2015.**	**2016.**	**2017.**	**2018.**	**2019.**
Belgija	36,7	35,56	37	34,82	37,94	35,21	35,36	36,55	34,23	35,9	36,39	36,09	36,37	35,76
Bugarska	10,51	10,33	9,97	8,59	8,83	9,25	9,22	8,78	8,99	9,49	9,65	9,89	9,91	9,84
Češka	26,54	26,08	25,93	24,94	25,25	24,46	24,41	24,21	23,58	24,19	24,82	25,5	25,33	25,24
Danska	15,66	15,72	15,53	14,79	15,52	14,8	14,29	14,12	13,66	14,2	14,54	14,55	14,58	14,33
Njemačka	225,35	212,95	221,71	208,25	223,02	211,71	215,78	220,97	209,93	212,68	216,81	218,57	215,46	214,54
Estonija	2,89	3,1	3,09	2,77	2,91	2,85	2,9	2,89	2,82	2,8	2,84	2,87	2,96	2,9
Irska	13,13	13,12	13,17	11,78	11,86	11,06	10,75	10,84	10,87	11,28	11,7	11,86	12,44	12,36
Grčka	21,63	22,1	21,44	20,58	19,06	18,92	17,06	15,34	15,58	16,56	16,76	16,42	15,93	16,19
Španjolska	95,82	98,48	95,01	88,05	89,44	86,92	83,4	80,95	79,42	80,59	82,52	84,9	86,89	86,3
Francuska	157,74	153,82	155,82	149,53	153,96	149,19	153,54	156,23	145,4	148,42	150,35	149,37	146,84	145,45
Hrvatska	**7,26**	**7,29**	**7,4**	**7,18**	**7,21**	**6,96**	**6,66**	**6,57**	**6,24**	**6,59**	**6,64**	**6,92**	**6,85**	**6,91**
Italija	135,66	134,62	134,28	126,17	128,51	123,18	121,82	118,55	113,31	116,22	115,92	115,19	116,44	115,5
Cipar	1,87	1,93	1,97	1,94	1,93	1,92	1,77	1,62	1,62	1,67	1,77	1,87	1,86	1,89
Latvija	4,19	4,35	4,15	4,04	4,12	3,87	4,03	3,86	3,89	3,79	3,82	4,01	4,18	4,08
Litva	4,93	5,21	5,13	4,64	4,81	4,78	4,9	4,78	4,88	4,86	5,1	5,34	5,57	5,56
Luksemburg	4,41	4,34	4,38	4,08	4,33	4,29	4,17	4,12	4	3,99	4,04	4,18	4,35	4,39
Mađarska	18,46	17,44	17,44	17,07	17,45	17,49	16,47	16,58	16,22	17,4	17,78	18,48	18,51	18,61
Malta	0,47	0,48	0,5	0,45	0,5	0,49	0,51	0,53	0,55	0,58	0,58	0,62	0,66	0,7
Nizozemska	53,76	53,06	53,91	51,68	55,34	51,68	51,82	51,92	47,61	48,82	49,87	50,23	50,66	49,89
Austrija	27,88	27,59	27,75	26,4	28,02	27,18	27,22	27,87	26,79	27,5	28,07	28,53	27,83	28,28
Poljska	61,22	61,62	62,49	61,52	66,28	64,67	64,43	63,25	61,55	62,3	66,6	70,92	71,82	70,97
Portugal	18,74	18,96	18,45	18,24	18,15	17,36	16,03	15,84	15,76	16	16,19	16,56	16,87	17,13
Rumunjska	24,77	24,14	24,68	22,24	22,54	22,74	22,76	21,8	21,69	21,85	22,24	23,33	23,59	23,88
Slovenija	5,12	5,14	5,5	4,86	5,07	5,05	4,92	4,81	4,61	4,71	4,88	4,95	4,95	4,85
Slovačka	11,37	11,2	11,45	10,63	11,54	10,77	10,34	10,59	9,96	10,06	10,4	11,13	11,11	11,17
Finska	26,51	26,55	25,64	23,82	26,21	24,99	25,15	24,68	24,52	24,21	25,18	25,26	25,84	25,32
Švedska	33,15	33,29	32,69	31,39	33,99	32,54	32,57	32,03	31,22	31,8	32,26	32,14	31,95	31,57

Izvor: Izrada autora na temelju podataka iz baze Eurostat.

Preuzeto s: https://ec.europa.eu/eurostat/databrowser/view/nrg_ind_eff/default/table?lang=en

Potrošnja finalne energije u Republici Hrvatskoj bila je na najvišoj razini 2007. godine i iznosila je 7,29 Mtoe, dok se 2014. godine bilježi kontinuirano smanjenje potrošnje finalne energije. Od 2015. do 2017. godine potrošnja finalne energije je u porastu te se 2018. godine bilježi pad u potrošnji finalne energije (6,85 Mtoe). Porast u potrošnji finalne energije zabilježen je 2019. godine (6,91 Mtoe).

Dinamika promjene u potrošnji finalne energije za zemlje članice EU prikazana je na slici 7. Prosječna potrošnja finalne energije u razdoblju od 2017. do 2019. godine uspoređena je s potrošnjom finalne energije u 2020. godini.

Slika 7 Prosječna promjena u potrošnji finalne energije u razdoblju od 2017. do 2019. godine

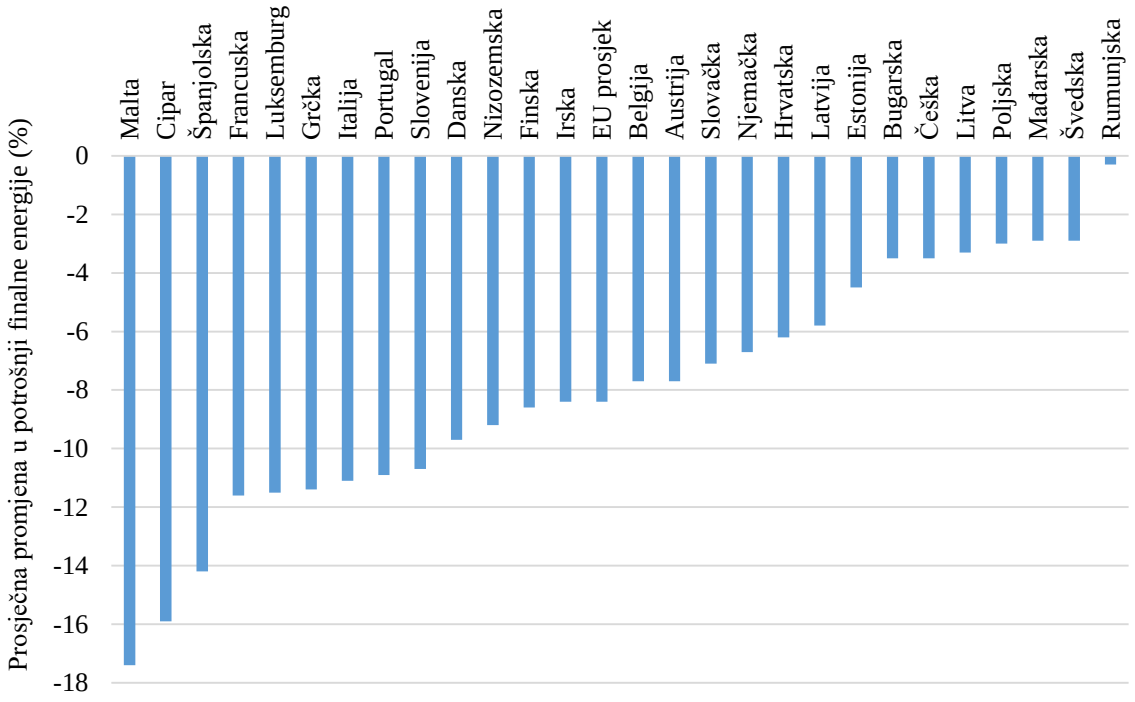

Izvor: Eurostat (2021) Energy saving statistics. Preuzeto s: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Energy_saving_statistics#Country_specific_evolution

Najznačajnije smanjenje u potrošnji finalne energije u navedenom razdoblju ostvareno je u Malti (17,4 %), Cipru (15,9 %) te Španjolskoj (14,2 %) dok je najmanje smanjenje potrošnje finalne energije zabilježen u Rumunjskoj (0,3 %), Švedskoj (2,9 %) i Mađarskoj (2,9 %). Prosječna je potrošnja finalne energije Republike Hrvatske u razdoblju od 2017. do 2019. godine niža za 6,2 % od potrošnje finalne energije u 2020. godini. Smanjenje u potrošnji finalne energije na razini EU iznosilo je 8,4 % (Eurostat, 2021).

Dostignuti su ciljevi u potrošnji primarne i finalne energije za 2020. godinu i kreću se smjeru ostvarenja postavljenih ciljeva za 2030. godinu. Ciljevi u potrošnji primarne energije za 2020. premašeni su za 5,8 % te ciljevi u potrošnji finalne energiju za 5,4 %. Potrebno je razlučiti u kojoj je to mjeri posljedica donesenih politika i mjera vezanih uz energetsku učinkovitost za postizanje ciljne potrošnje za 2020. godinu ili posljedica smanjene industrijske proizvodnje na području EU, ekonomske krize i/ili posljedica pandemije virusa Covid-19 koja je zasigurno obilježila 2020. godinu.

Na razini EU povećanjem energetske učinkovitosti nastoji se smanjiti potrošnja energije kroz primjenu različitih mjera i aktivnosti u različitim područjima od industrije, prometa, usluga, javne rasvjete do zgradarstva. Sljedeća poglavlja usmjeriti će se na energetsku učinkovitost i potrošnju energije u sektoru zgradarstva.

2.3. Energetska učinkovitost u sektoru zgradarstva

Sektor zgradarstva prepoznat je kao značajan potencijal za smanjenje potrošnje energije kroz povećanje energetske učinkovitosti na što ukazuje i Direktiva 2010/31/EU o energetskoj učinkovitosti zgrada. Potencijal zgrada u ostvarenju ušteda u energiji nalazi se u nekoliko sljedećih razloga (Buildings Performance Institute Europe, 2020; Arcipowska i Mariottini, 2016):

- na razini EU zgrade su najveći pojedinačni potrošač energije,
- generiraju približno 40 % potrošnje energije u EU i 36 % emisije stakleničkih plinova,
- oko 35 % zgrada u EU starije su od 50 godina,
- gotovo 75 % građevinskog fonda energetski je neučinkovito,
- gotovo 85-95 % postojećih zgrada i dalje će biti u upotrebi 2050. godine.

Ostvarivanje energetski visokoučinkovitog i dekarboniziranog fonda zgrada do 2050. godine jedan je od ciljeva EU. Postavljen cilj može se ostvariti izgradnjom zgrada nulte potrošnje energije te obnovom i povećanjem energetske učinkovitosti postojećeg fonda zgrada. Na temelju obveza koje proizlaze iz *Direktive 2010/31/EU* od 19. svibnja 2010. godine o energetskoj učinkovitosti zgrada gradnja novih zgrada i moguća obnova zgrada treba biti prema kriterijima za zgrade gotovo nulte energije. Zgrada gotovo nulte energije (engl. *nZEB - nearly zero-energy building*) označava zgradu vrlo visokih energetskih svojstava. Takve zgrade troše vrlo nisku količinu energije, a koja se u značajnoj mjeri dobiva energijom iz

obnovljivih izvora uključujući onu koja se proizvodi na samoj zgradi ili u njezinoj blizini (Ministarstvo prostornoga uređenja, graditeljstva i državne imovine, n.d.).

Zemlje članice EU obvezne su uspostaviti dugoročnu strategiju obnove nacionalnog fonda zgrada koja je ujedno dio nacionalnih energetskih i klimatskih planova (Europska komisija, n.d.). Povećanje energetske učinkovitosti energetski neučinkovitih zgrada može dovesti do značajnih ušteda energije, odnosno potrošnja energije u EU-u mogla bi se smanjiti za ukupno 5 - 6 % te emisija CO_2 za približno 5 % (Europska komisija, n.d.). Mjerljivost postavljenih ciljeva važan je element u nacionalnim strategijama o energetskoj učinkovitosti. Nacionalne strategije moraju uključivati indikatore za mjerenje napretka ostvarenih ciljeva, indikativne vrijednosti ciljeva za 2030., 2040. i 2050. godinu ali i procjenu energetskih ušteda i općih koristi koje proizlaze iz povećanja energetske učinkovitosti u zgradarstvu (Europska komisija, 2019). Nacionalne strategije energetske obnove zgrada moraju uključivati (Europska komisija, 2019):

- pregled nacionalnog fonda zgrada,
- politike i mjere za poticanje isplative obnove zgrada,
- politike i mjere usmjerene ka zgradama s najlošijim energetskim svojstvima,
- politike i mjere usmjerene ka transparentnoj podjeli sredstava, smanjenju energetskog siromaštva, zgradama javne namjene,
- pregled nacionalnih inicijativa za promicanje pametnih tehnologija i vještina te obrazovanja u sektorima građevine i energetske učinkovitosti.

Prilikom kreiranja mjera i politika usmjerenih ka zgradama s najlošijim energetskim svojstvima države članice moraju identificirati one zgrade iz svojeg nacionalnog fonda zgrada koje imaju najlošija energetska svojstva bilo određivanjem određenog praga, kao energetski razred, na temelju potrošnje primarne energije (izražene u kWh/m^2) ili usmjeravanjem pozornosti na zgrade izgrađene prije određenog datuma (Europska komisija, 2019).

Potrošnja energije u zgradama ovisi o brojnim čimbenicima. Namjena zgrade svakako je jedan od tih čimbenika. Zgrade se dijele na stambene i nestambene zgrade (Državni zavod za statistiku, 2001). Stambena zgrada označava obiteljsku kuću ili višestambenu zgradu koja je u cijelosti ili u kojoj je više od 90 % građevinske (bruto) površine namijenjeno za stanovanje (Pravilnik o energetskom pregledu zgrade i energetskom certificiranju, NN 88/17, NN 90/20, NN 01/21, NN 45/21).

U Hrvatskom zakonodavstvu nestambena zgrada definirana je kao zgrada koja nema niti jednu stambenu jedinicu ili skup prostorija namijenjen stanovanju zajednica (Pravilnik o energetskom pregledu zgrade i energetskom certificiranju, NN 88/17, NN 90/20, NN 01/21, NN 45/21). Nestambene zgrade čine uredski prostori, komercijalni prostori, obrazovni objekti, zdravstveni objekti, vjerski objekti. Radi heterogenosti nestambenih zgrada, za razliku od stambenih zgrada, dostupne su vrlo ograničene informacije kako o građevinskim karakteristikama, instaliranim sustavima za različite usluge, načinu korištenja energije (Droutsa i suradnici, 2020) te pojedinačnim skupinama zgrada koje pripadaju nestambenom sektoru što otežava njihovu usporedivost na razini EU.

D'Agostino i suradnici (2017) navode kako različite definicije nestambenih zgrada ukazuju na neusklađen pristup u praćenju potrošnje energije u nestambenom sektoru ali i potrebu za sistematičnim prikupljanjem podataka i informacija o nestambenim zgradama. Autori ukazuju na različita tumačenja termina „nestambene zgrade“ i navode primjere tumačenja Organizacije za ekonomsku suradnju i razvoj (engl. *Organisation for Economic Co-operation and Development - OECD*) u odnosu na tumačenje u bazi Eurostat. Prema OECD-u (2021) nestambenom zgradom smatra se ona zgrada kod koje se manje od polovice bruto površine koristi za stanovanje te nestambene zgrade koje obuhvaćaju industrijske zgrade, poslovne zgrade, obrazovne zgrade, zdravstvene zgrade i ostale zgrade. Prema tumačenju iz baze Eurostat (2018) nestambena je zgrada ona zgrada koja se uglavnom koristi ili je namijenjena u nestambene svrhe. U ovoj bazi u nestambene zgrade ubrajaju se sve zgrade koje nisu namijenjene stanovanju ali i uređaji, objekti i oprema koji su sastavni dijelovi građevina, povijesni spomenici, skladišne i industrijske zgrade, poslovne zgrade, hoteli, restorane, obrazovne zgrade, zdravstvene zgrade itd..

U različitim studijama, statističkim prikazima i izvješćima (npr. studija Europske komisije (2016) *Mapping and analyses of the current and future (2020 - 2030) heating/cooling fuel deployment (fossil/renewables),* statistički prikaz baze Odyssee-Mure - *Sectoral profile - overview,* statistički prikaz baze Eurostat *Final energy consumption by sector,* izvješće Energetskog instituta Hrvoje Požar - *Godišnji energetski pregled – Energija u Hrvatskoj 2020 itd.)* potrošnja energije nestambenih zgrada iskazuje se u sumarnim vrijednostima pod zajedničkim nazivnikom *tercijarni sektor, servisni sektor ili sektor opće potrošnje*.

Odnosno, prikazi i izvješća opisuju ukupnu potrošnju energije zgrada koja je generirana u različitim ekonomskim podsektorima koji pripadaju tercijarnom sektoru ali i upotreba energije

za potrebe ulične rasvjete, prozračivanje tunela, javno prometne infrastrukture. Podsektori tercijarnog sektora definirani prema *Statističkoj klasifikaciji gospodarskih djelatnosti* (engl. *Statistical classification of economic activities in the European Community - NACE*) za koje se promatra potrošnja energije u nestambenim zgradama prikazani su u tablici 4.

Tablica 4 Podsektori tercijarnog sektora

Ekonomski podsektor	Klasa	Opis
Trgovina	G	Trgovina na veliko i malo
Hoteli i restorani	I	Hoteli i restorani, kampovi, planinski objekti, barovi, menze, ugostiteljstvo
Financijske djelatnosti i djelatnosti osiguranja	K	Financije i osiguranje
Zdravstvo	Q	Zdravstveni i socijalni rad, bolničke djelatnosti, djelatnosti socijalne skrbi sa smještajem
Obrazovanje	P	Osnovno i srednje obrazovanje, visoko obrazovanje, djelatnosti vozačkih škola
Javna administracija	O	Javna uprava i obrana; obvezno socijalno osiguranje
Ostale usluge	L, M, N, R, S	Administrativne i pomoćne uslužne djelatnosti, umjetnost, zabava i rekreacija, nekretnine i ostale uslužne djelatnosti

Izvor: Europska komisija (2016) Mapping and analyses of the current and future (2020 - 2030) heating/cooling fuel deployment (fossil/renewables)

Iz tablice 4 vidljivo je da je heterogenost izraz koji može opisati strukturu fonda nestambenih zgrada. Fond nestambenih zgrada čine različiti tipovi zgrada s različitim namjenama i veličinama te energetskim karakteristikama (D'Agostino i suradnici, 2017). Podaci o nestambenim zgradama često su nepotpuni i nerijetko su prikazani na razini ukupne potrošnje energije za sve nestambene zgrade. Podaci o nestambenim zgradama na razini EU su neujednačeni i postoji značajna razlika u izvještavanju i izmjerenoj i/ili izračunatoj potrošnji energije u zgradama. Kako bi se omogućilo bolje razumijevanje energetske učinkovitosti građevinskog sektora u sklopu paketa *Čista energija za sve Europljane* uspostavljena je baza *Building Stock Observatory (BSO)* čiji je cilj prikupljanje pouzdanih, konzistentnih i usporedivih podataka o zgradama (Europska komisija, n.d.).

BSO sadrži bazu podataka, mapu podataka i informativne tablice za praćenje energetske učinkovitosti zgrada diljem Europe te obuhvaća širok spektar energetskih tema i pruža informacije o fondu zgrada, potrošnji energije, elementima zgrada i instaliranim tehničkim sustavima zgrada, energetskim certifikatima, zgradama gotovo nulte potrošnje energije i stopama obnove, ali i područjima poput energetskog siromaštva (Europska komisija, n.d.). Međutim, nisu dostupni podaci o nestambenim zgradama, potrošnji energije i energetskim certifikatima za brojne zemlje članice, a za one zemlje članice za koje su podaci dostupni ovisno o tipu pretrage dostupni su podaci za pojedine godine.

Na razini EU postoji 12 milijuna nestambenih zgrada od čega je 24 % javnih i privatnih ureda, 23 % trgovina na veliko i malo, 18 % obrazovnih zgrada, 14 % ostalo, 11 % zgrada iz sektora zdravstva te 10 % hotela i restorana (Rics, 2020). Prosječna godišnja potrošnja po m² za sve vrste zgrada na razini EU je oko 200 kWh/m². Međutim, nestambene zgrade u prosjeku su 60 % energetski intenzivnije od stambenih zgrada (300 kWh/m² u odnosu na 170 kWh/m²) (Rousselot i Pinto Da Rocha, 2021).

Potrošnja energije u zgradama razlikuje se ovisno o krajnjoj namjeni. Za nestambene zgrade promatra se potrošena energija za potrebe grijanja zgrade, hlađenja, zagrijavanja tople vode, opreme, ventilacije, rasvjete. Od prethodno navedenog najveći udio u potrošnji energije, kako u nestambenim tako i u stambenim zgradama, jest energija potrošena za potrebe grijanja prostora. Energija potrošena za potrebe grijanja prostora čini 61 % ukupne potrošnje na razini EU te u kombinaciji s potrebnom energijom za zagrijavanje vode pokriva 75 % konačne potrebe za energijom u tercijarnom sektoru za grijanje (Europska komisija, Directorate-General for Energy, 2016). Udio potrošene energije za potrebe grijanja nestambenih zgrada u ukupnoj potrošnji energije varira u zemljama članicama. U Francuskoj iznosi 85 %, u Njemačkoj i Poljskoj taj udio iznosi 72 %, Ujedinjenom Kraljevstvu 88 % te u Nizozemskoj 100 % potrošene energije u nestambenim zgradama je za potrebe grijanja prostora (Europska komsija, Directorate-General for Energy, 2016). U Republici Hrvatskoj toplinska energija zauzima najveći udio u potrošnji finalne energije. U kontinentalnoj Hrvatskoj taj je udio prosječno 80 %, dok u primorskoj Hrvatskoj iznosi prosječno 51 %. U obrazovnim institucijama udio toplinske energije u finalnoj potrošnji energije prosječno iznosi oko 85 % te u bolnicama on prosječno iznosi oko 78 % (Vlada Republike Hrvatske, 2017). Potrošnja toplinske energije uključuje potrošnju energije za potrebe grijanja te za potrebe zagrijavanja tople vode.

Energetsko certificiranje zgrade provodi se s ciljem utvrđivanja energetskih svojstva pojedine zgrade (Pravilnik o energetskom pregledu zgrade i energetskom certificiranju, NN 88/17, NN 90/20, NN 01/21, NN 45/21). Postupak energetskog certificiranja u Republici Hrvatskoj obvezan je za zgrade javne namjene čija ukupna korisna površina prelazi 250 m², nove zgrade prije izdavanja uporabne dozvole osim ako *Pravilnikom o energetskom pregledu zgrade i energetskom certificiranju* nije drukčije propisano, zgrade koje se prodaju, iznajmljuju, daju u zakup ili najam (engl. *leasing*) (Pravilnik o energetskom pregledu zgrade i energetskom certificiranju, NN 88/17, NN 90/20, NN 01/21, NN 45/21).

Certifikat o energetskoj učinkovitosti (EPC) osnovni je instrument *Direktive o energetskoj učinkovitosti zgrada* za utvrđivanje energetskih svojstva zgrade, odnosno koliko učinkovito zgrada troši energiju (Droutsa i suradnici, 2020). Energetsko certificiranje predstavlja „*skup radnji i postupaka koji se provode u svrhu izdavanja energetskog certifikata te uključuje: energetski pregled zgrade, potrebne proračune za referentne klimatske podatke za iskazivanje specifične godišnje potrebne toplinske energije za grijanje, specifične godišnje potrebne toplinske energije za hlađenje, specifične godišnje isporučene energije, specifične godišnje primarne energije, specifične godišnje emisije* CO_2*, određivanje energetskog razreda zgrade, izradu energetskog certifikata*“ (Pravilnik o energetskom pregledu zgrade i energetskom certificiranju, NN 88/17, NN 90/20, NN 01/21, NN 45/21, članak 16).

Energetski certifikat predstavlja „zdravstvenu“ iskaznicu zgrade koja sadrži: „*opće podatke o zgradi, energetski razred zgrade, rok važenja certifikata, podatke o osobi koja je izdala i izradila energetski certifikat, podatke o osobama koje su sudjelovale u izradi energetskog certifikata, oznaku energetskog certifikata, podatke o termotehničkim sustavima, energetske potrebe zgrade, podatke o korištenju obnovljivih izvora energije, prijedlog mjera, detaljnije informacije i objašnjenje sadržaja energetskog certifikata*“ (Pravilnik o energetskom pregledu zgrade i energetskom certificiranju, NN 88/17, NN 90/20, NN 01/21, NN 45/21). Energetski certifikat daje dva važna podatka o potrošnji energije zgrade: energetski razred zgrade označen slovom (A+, A, B, C, D, E, F, G) s podatkom o *specifičnoj godišnjoj potrebnoj toplinskoj energiji za grijanje za referentne klimatske podatke izraženoj u kWh/(m²a)* te energetski razred zgrade označen slovom (A+, A, B, C, D, E, F, G) s podatkom o *specifičnoj godišnjoj primarnoj energiji,* E_{prim} *izraženoj u kWh/m²a.*

Energetski razred grafički se prikazuje na energetskom certifikatu zgrade slovom (A+, A, B, C, D, E, F, G) s podatkom o *specifičnoj godišnjoj potrebnoj toplinskoj energiji za grijanje za referentne klimatske podatke izraženoj u kWh/m²a* i određuje se prema tablici 5.

Tablica 5 Specifična godišnja potrebna energija za grijanje za referentne klimatske podatke

Energetski razred	$Q_{H, nd, ref}$ specifična godišnja potrebna toplinska energija za grijanje za referentne klimatske podatke u kWh/m²a
A+	<= 15
A	<= 25
B	<= 50
C	<= 100
D	<= 150
E	<= 200
F	<= 250
G	> 250

Izvor: Pravilnik o energetskom pregledu zgrade i energetskom certificiranju, NN 88/2017-2093

Energetski razred grafički se prikazuje na energetskom certifikatu zgrade slovom s podatkom o *specifičnoj godišnjoj primarnoj energiji, E_{prim} izraženoj u kWh/m²a* te se definira prema tablici 6.

Tablica 6 Specifična godišnja primarna energija, E_{prim} izražena u kWh/m²a.

E_{prim} (kWh/m^2a)	Uredska		Obrazovna		Bolnica		Sportska dvorana		Ostale nestambene	
Energetski razred	*K*	*P*	*K*	*P*	*K*	*P*	*K*	*P*	*K*	*P*
A+	≤ 35	≤ 25	≤ 55	≤ 55	≤ 250	≤ 250	≤ 210	≤ 150	≤ 80	≤ 50
A	> 35 ≤ 55	> 25 ≤ 50	> 55 ≤ 60	> 55 ≤ 58	> 250 ≤ 275	> 250 ≤ 275	> 210 ≤ 305	> 150 ≤ 160	> 80 ≤ 115	> 50 ≤ 75
B	> 55 ≤ 70	> 50 ≤ 70	> 60 ≤65	> 58 ≤ 60	> 275 ≤ 300	> 275 ≤ 300	> 305 ≤ 400	> 160 ≤ 170	> 115 ≤ 150	> 75 ≤ 100
C	> 70 ≤ 100	> 70 ≤ 90	> 65 ≤ 125	> 60 ≤ 120	> 300 ≤ 345	> 300 ≤ 325	> 400 ≤ 465	> 170 ≤ 225	> 150 ≤ 280	> 100 ≤ 225
D	> 100 ≤ 125	> 90 ≤ 110	> 125 ≤ 175	> 120 ≤ 175	> 345 ≤ 395	> 325 ≤ 350	> 465 ≤ 530	> 225 ≤ 280	> 280 ≤ 410	> 225 ≤ 350
E	> 125 ≤ 155	> 110 ≤ 140	> 175 ≤ 220	> 175 ≤ 220	> 395 ≤ 495	> 350 ≤ 440	> 530 ≤ 665	> 280 ≤ 350	> 410 ≤ 515	> 350 ≤ 435
F	> 155 ≤ 190	> 140 ≤ 165	> 220 ≤ 265	> 220 ≤ 265	> 495 ≤ 590	> 440 ≤ 525	> 665 ≤ 795	> 350 ≤ 415	> 515 ≤ 615	> 435 ≤ 520
G	> 190	>165	> 265	> 265	> 590	> 525	> 795	> 415	> 615	> 520

Izvor: Izrada autora, prilagođeno iz Pravilnika o energetskom pregledu zgrade i energetskom certificiranju, NN 88/17, NN 90/20, NN 01/21, NN 45/21

Iz tablice 6 isključeni su podaci vezani uz obiteljske kuće i višestambene objekte. Energetski razred grafički se prikazuje na energetskom certifikatu zgrade slovom (A+, A, B, C, D, E, F, G) s podatkom o specifičnoj godišnjoj primarnoj energiji, E_{prim} izraženoj u kWh/m²a (Pravilnik o energetskom pregledu zgrade i energetskom certificiranju, NN 88/17, NN 90/20, NN 01/21, NN 45/21). Energetski razredi kreću se od oznake A+ što označava da je zgrada energetski vrlo učinkovita do oznake G koja označava energetski najlošija svojstva zgrade.

Energetski certifikat nit je vodilja prilikom provođenja energetskih politika vezanih uz potrošnju energije u zgradama. Uloga je energetskog certifikata dvostruka (Geissler i suradnici, 2019): prikazati energetsku učinkovitost zgrade i informirati korisnike o energetskim svojstvima zgrade te pružiti bazu podataka za planiranje, provedbu i kontrolu uštede energije i smanjenja CO_2 te izradu strategija i mjera za cjelokupni građevinski sektor.

Baze energetskih certifikata u zemljama članicama trebale bi predstavljati jedan od najboljih izvora informacija o EU zgradama. Međutim, podaci u bazama često su nepotpuni i usporedivost između različitih zemalja (i regija) je ograničena. Prema Volt i suradnicima (2020) uzrok je tome neadekvatno prikupljanje podataka, nedostatak usklađenosti, različite EPC definicije te metode izračuna.

Neupitna je važnost energetskog certificiranja i energetskih certifikata u procesu kreiranja nacionalnih energetskih politika usmjerenih na sektor zgradarstva te za postizanje zadanih ciljeva vezanih uz potrošnju i uštedu energije. No, nerijetko očekivana potrošnja energije pojedine zgrade iskazana putem energetskog certifikata odstupa od stvarne potrošnje energije. To dovodi do svojevrsnog paradoksa u potrošnji energije. Značajna odstupanja između proračunskih i stvarnih vrijednosti u potrošnji dovode i do odstupanja u planiranoj dinamici energetske obnove te očekivanim uštedama koje bi trebale proizaći iz nje.

2.3.1. Odstupanje u potrošnji energije u zgradama

Brojni istraživači uočili su raskorak između očekivane proračunske potrošnje energije i stvarne potrošnje energije u zgradama. U literaturi je to odstupanje poznato pod zajedničkim nazivom odstupanje ili jaz u potrošnji energije (engl. *energy performance gap*). Proračunskom (očekivanom) potrošnjom energije smatra se ona potrošnja koja proizlazi iz tehničkih izračuna prilikom projektiranja zgrade, energetskog certificiranja i sl., dok se pod stvarnom potrošnjom

energije podrazumijeva potrošena energija koju generira zgrada prilikom upotrebe (Van Dronkelaar i suradnici, 2016).

Fenomen je odstupanja u potrošnji energije u svom tumačenju širok i pod njim se mogu promatrati proračunski izračuni u potrošnji energije kako na ukupnoj razini, tako i za pojedinog krajnjeg potrošača (potrošnja energije za grijanje i hlađenje, potrošnja energije za zagrijavanje tople vode, potrošnja energije za rasvjetu i sl.) i usporediti sa stvarnim vrijednostima potrošnje koje zgrada generira. De Wilde (2014) razlikuje tri glavne skupine izmjerenih odstupanja koja se pojavljuju u literaturi: 1) između proračunskih vrijednosti nastalih u fazi projektiranja i stvarnih performansa zgrada, 2) između predviđene potrošnje energije na temelju različitih modela strojnog učenja i stvarnih performansi zgrada te 3) između energetskih razreda prikazanih na energetskim certifikatima i energetskih procjena dobivenih na temelju različitih metoda izračuna.

Svrha je svakog modela ostvariti što manju grešku predviđanja, tako je i svrha modela za izračun energetske učinkovitosti prikazati što točnije ponašanje zgrade vezano uz potrošnju energije. Važno je promotriti magnitudu odstupanja s ciljem poboljšanja postojećih proračunskih modela i razumijevanje potrošnje energije u zgradama. Veliko istraživanje o odnosu između stvarne potrošnje energije i predviđene potrošnje energije provele su organizacije RIBA (engl. *Royal Institute of British Architects - RIBA*) i CIBSE (engl. *Chartered Institution of Building Services Engineers - CIBSE*) u Ujedinjenom Kraljevstvu (UK) koje su uspostavile platformu CarbonBuzz za usporedbu (engl. *benchmarking*) i praćenje potrošnje energije u zgradama od faze projektiranja do faze uporabe. U svom istraživanju zaključuju da uredske zgrade troše 1,59 puta više energije za potrebe grijanja u odnosu na proračunske vrijednosti potrošnje energije za potrebe grijanja, dok su kod obrazovnih institucija uočili 1,48 puta veću stvarnu potrošnju energije za potrebe grijanja u odnosu na proračunsku potrošnju energije za potrebe grijanja (CarbonBuzz, n.d.). Pregled postojećih istraživanja o odstupanju između stvarne potrošnje energije i proračunske potrošnje energije provela je i organizacija IPECC (engl. *International Partnership for Energy Efficiency Cooperation - IPEEC*). Istraživanjem zaključuju da je magnituda odstupanja u potrošnji energije veća u nestambenim zgradama u odnosu na odstupanje u potrošnji energije u stambenim zgradama. Ujedno, uočavaju da istraživanja o jazu u potrošnji energije koja obuhvaćaju relativno malen uzorak pokazuju veću magnitudu odstupanja i to u rasponu od 150 % do 250 % u odnosu na stvarnu

potrošnju energije dok istraživanja temeljena na većem uzorku bilježe odstupanja u rasponu od 10 % do 30 % (International Partnership for Energy Efficiency Cooperation - IPEEC, 2019)

Herrando i suradnici (2016) analizirali su odstupanja između proračunske potrošnje energije iskazane na energetskim certifikatima i stvarne potrošnje energije za 21 fakultetsku zgradu na Sveučilištu u Zaragozi u Španjolskoj. Istraživanjem utvrđuju da stvarna potrošnja energije odstupa u prosjeku 30 % u odnosu na potrošnju energije predviđenu energetskim certifikatom. Kako bi se smanjio navedeni jaz u potrošnji energije, autori naglašavaju potrebu identifikacije onih aktivnosti koje troše najviše energije u zgradi i sugeriraju promjenu upravo u tim aktivnostima jer svaka i najmanja promjena može u konačnici dovesti do velikih ušteda u potrošnji energije. Autori smatraju da se podučavanjem korisnika zgrada dobrim praksama energetske učinkovitosti, kao i povećanjem svijesti javnosti o ovom pitanju, mogu postići potencijalne uštede energije.

Istraživanje na pet nisko energetskih zgrada u UK proveo je Pegg (2007). Karakteristike odabranih zgrada bile su sljedeće: izgrađene u razdoblju između 2001. i 2005. godine, s namjenom srednjoškolskog obrazovanja, bruto površine između 7000 m² i 14000 m² te sličnih konstrukcijskih karakteristika. Autor je utvrdio odstupanje stvarne potrošnje energije u rasponu od 30 % do 45 % od proračunske potrošnje za potrebe grijanja. Kao uzrok tome autor navodi uvođenje informacijsko-komunikacijskih tehnologija u nastavu, produljeno radno vrijeme – izvannastavne aktivnosti i nedostatak upravljanja energijom.

Majcen i suradnici (2013) proveli su opsežno istraživanje na 200 000 objekata u Nizozemskoj gdje su usporedili potrošnju energije iskazanu na energetskom certifikatu i stvarnu potrošnju energije. Autori su došli do zanimljivog zaključka: objekti s lošijim energetskim razredom imali su nižu stvarnu potrošnju energije od one predviđene energetskim certifikatom dok su objekti s višim energetskim razredom imali veću stvarnu potrošnju od one predviđene energetskim certifikatom.

Cozza i suradnici (2020) proveli su istraživanje na 1172 zgrade u Švicarskoj za koje su bili dostupni energetski certifikati prije i poslije energetske obnove te stvarna potrošnja energije. Stvarna potrošnja energije u zgradama bila je niža za prosječno 23 % u odnosu na certificiranu potrošnju prema energetskom certifikatu prije energetske obnove. Autori navode da su time i procjene ušteda bile precijenjene za 37 %. Nakon što su usporedili stvarnu potrošnju energije s potrošnjom iskazanom na energetskim certifikatima napravljenima nakon energetske obnove

utvrđuju kako je stvarna potrošnja energije bila veća za prosječno 2 % u odnosu na potrošnju energije predviđene energetskim certifikatom nakon procesa energetske obnove dok su projekcije ušteda bile su precijenjene za 2,6 %. Autori navode da se uštede energije mogu prilično točno procijeniti uspoređivanjem stvarne trenutne potrošnje s očekivanom proračunskom potrošnjom definiranom certifikatom ali tek nakon provedene energetske obnove.

Odstupanje u potrošnji može se promatrati u oba smjera. Stvarna potrošnja energije može biti veća od proračunske potrošnje, ali isto tako može biti i niža od proračunske potrošnje. Katić i suradnici (2021) su u provedenom istraživanju identificirali 65 % nižu stvarnu potrošnju energije u odnosu na proračunsku potrošnju energije za potrebe grijanja. Autori su istraživanje proveli na 185 zgrada obrazovne namjene u Bosni i Hercegovini. Autori zaključuju da uštede u potrošnji energije nisu proizašle kao posljedica poboljšanja energetskih svojstava već zbog ustezanja u potrošnji energije. Kao razlog manje potrošnje energije autori navode nedostatak financijskih sredstava za kupnju potrebnih energenata za grijanje, ne zagrijavanje svih dijelova zgrade (hodnik, toalet, dio učionica i sl.) što svakako utječe na osjećaj ugode boravka u zgradi.

Utvrđivanje značajno niže stvarne potrošnje koja je posljedica ustezanja od korištenja, a ne produkt povećane efikasnosti važno je radi otkrivanja i sprječavanja energetskog siromaštva.

Uzrok odstupanja proračunske potrošnje energije u odnosu na stvarnu potrošnju energije može počivati u bilo kojem životnom ciklusu zgrade: od faze projektiranja zgrade (ograničenja, netočnosti i pretpostavke u modelima koji se koriste za predviđanje energetske učinkovitosti, kompleksnosti projekta); faze izgradnje (loša kvalitete izrade i razlike između pretpostavljenih i stvarnih materijala, komponenti i sustava, odstupanje od projekta i sl.); te u fazi uporabe zgrade (loše upravljanje energijom u zgradama i/ili nepoklapanje između pretpostavljene i stvarne upotrebe zgrade, utjecaj korisnika) (Shi i suradnici, 2019; Van Dronkelaar i suradnici, 2016).

Menezes i suradnici (2012) u svom istraživanju navode korištenje nerealnih pretpostavki u postojećim modelima za izračun potrošnje energije kojima se opisuje način korištenja i upravljanja zgradama kao jedan od razloga zbog kojih dolazi do odstupanja u potrošnji energije. Van Dronkelaar i suradnici (2016) navode značajan utjecaj korisnika u potrošnji energije zgrade u smislu upravljanja rasvjetom, prozorima, uredskom opremom pa čak i svojom prisutnošću. Posebno ističu pitanje noćne potrošnje energije koja proizlazi iz

neisključivanja opreme i pretpostavki o radnim satima i produženim radnim satima koje nisu uzete u obzir prilikom modeliranja. Shi i suradnici (2019) navode da kretanje i fluktuacija korisnika ima značajan utjecaj za potrošnju energije. U energetskim modelima pretpostavlja se broj korisnika i radni sati na temelju tipova zgrade i funkcije prostora. Međutim, te pretpostavke mogu biti u potpunosti drukčije prilikom stvarne uporabe zgrade.

Magnituda jaza u potrošnji energije i potreba za njegovim smanjenjem ukazuju i na nužnost preispitivanja relevantnosti postojećih metoda i modela za energetsko certificiranje. Postojeći modeli za energetsko certificiranje nisu usmjereni na krajnje korisnike i njihovo ponašanje te se temelje isključivo na tehničkim karakteristikama i standardiziranim pretpostavkama o načinu korištenja zgrade. Van Dronkelaar i suradnici (2016) ističu da bi se odstupanje moglo značajno smanjiti ako se u izračune uključi stvarno ponašanje zgrade u radnim uvjetima i to definiraju pod nazivom modeliranje izvedbe (engl. *performance modeling*). Pod tim terminom uključuju sve metode kvantifikacije energije koje imaju za cilj točno predvidjeti performanse zgrade.

S obzirom na to da je uloga korisnika važan čimbenik u potrošnji energije u zgradama važno je potaknuti korisnike i upravitelje zgrada javnog sektora na odgovorno ponašanje u potrošnji energije u zgradama. To je moguće poticanjem odgovornog ponašanja pojedinaca, edukacijom te proaktivnim djelovanjem menadžmenta u upravljanju potrošnjom energije u zgradama.

2.4. Uloga javnog sektora u promicanju energetske učinkovitosti u zgradarstvu

Direktivom o energetskoj učinkovitosti (2012/27/EU) javni sektor u svim zemljama članicama obvezan je obnoviti „*3 % ukupne površine poda grijanih i/ili hlađenih zgrada u vlasništvu i uporabi središnje vlasti, odnosno da alternativnim pristupom postignu uštede energije u zgradama središnje vlasti jednak uštedama energije dobivenima putem stope obnove od 3 %*“ (Vlada Republike Hrvatske, 2017). Osim toga, javni sektor mora svojim primjerom energetske obnove postati lider u energetskoj obnovi i promicati pozitivnu sliku o energetskoj učinkovitosti (Vlada Republike Hrvatske, 2017) .

Provođenje mjera energetske učinkovitosti i obnove zgrada javnog sektora nije jednostavan proces. Javni sektor suočava se s dvojakim preprekama: preprekama koje se općenito vežu uz energetsku učinkovitosti te preprekama specifičnim za javni sektor (Gynther i Eichhammer, 2016; Patton, n.d.). Gynther i Eichhammer (2016) navode univerzalne prepreke u provođenju

mjera energetske učinkovitosti: marginalizacije energetske učinkovitosti, odnosno projekti energetske učinkovitosti nemaju prioritet nad drugim poslovnim aktivnostima u poduzećima, nedostatak stručnog kadara zaposlenog na puno radno vrijeme na poslovima vezanim uz projekte energetske učinkovitosti, nedostatak znanja iz područja upravljanja energijom, nedostatak svijesti o problemu potrošnje energije, vrlo visok percipirani rizik od novih učinkovitijih tehnologija te nepovjerenje u energetske preglede i mjere koje se donose na temelju toga. Prema Gynther i Eichhammer (2016) prepreke specifične za javni sektor su: donošenje odluka o projektima i promicanju energetske učinkovitosti je i na razini jedinica lokalne i regionalne samouprave te ponekad proces donošenja odluka ima političku konotaciju, a odluke se donose kratkoročno i ne promatra se dugoročno pitanje energetske učinkovitosti. Nadalje, ograničen proračunski budžet značajna je prepreka na putu ka većoj energetskoj učinkovitosti. Naime, projekti energetske obnove financiraju se iz istog proračuna kao i ostala davanja primjerice za školstvo, zdravstvo, sport, itd. te projekti energetske učinkovitosti obično čine manju proračunsku stavku i nisu u primarnom fokusu. Komplicirani postupci javne nabave te opsežna dokumentacija također su prepreke s kojima se susreće javni sektor u projektima energetske obnove zgrada.

Alam i suradnici (2019) pregledom postojećih istraživanja u ovom području osim financijskih barijera identificirali su: nedostatak odlučnosti vlade u provođenju projekata energetske učinkovitosti, potrebu za interdisciplinarnim pristupom u postizanju veće energetske učinkovitosti, slabu informiranost te motivaciju za uključivanje u programe energetske obnove. Uz sve prethodno navedeno, percepcija koristi koje proizlaze iz projekata energetske učinkovitosti ističe se kao snažna prepreka u provođenju projekta energetske učinkovitosti (Patton, n.d.). Zaposlenici u privatnom sektoru skloniji su prihvaćanju projekta za uštedu troškova dok državni službenici i namještenici smatraju da nemaju izravne koristi od smanjenja potrošnje energije i proizašlih ušteda iz projekta energetske učinkovitosti. Nužno je educirati korisnike i zaposlenike javnog sektora o važnosti energetske učinkovitosti (Patton, n.d.) i usmjeriti ih na nove načine djelovanja, promišljanja, odnosno promicati poduzetničke principe djelovanja i razmišljanja te otvorenost za inovacije i prihvaćanje novih tehnologija. U nastavku će se pokazat kako je poduzetničko promišljanje potrebno i u javnom sektoru, bez obzira na njegovu tradicionalno pasivnu karakteristiku.

Termin poduzetništva je multidimenzionalan i širi je od pukog pokretanja poslovnog poduhvata. Jedno od poznatih viđenja poduzetništva je Schumpeterovo (1934) koji stavlja

naglasak na inovacije koje se manifestiraju u obliku novih proizvoda, novih proizvodnih metoda, novih tržišta i novih oblika organizacija (Schumpeter,1934 preuzeto iz Sikalieh i suradnici, 2012). Inovacije opisuje kao „kreativnu destrukciju“ kako bi se stvorilo nešto novo i vrijednije što ujedno predstavlja i srce ekonomskog razvoja (Sikalieh i suradnici, 2012), a poduzetnika od ostalih dionika u gospodarskom sustavu razlikuje upravo spremnost za bavljenje inovativnom aktivnošću (Schumpeter, 1942 preuzeto iz Hayter i suradnici, 2018) Važna karakteristika poduzetničkog djelovanja je i prepoznavanje prilika, odnosno poduzetnik u promjenama i preprekama uočava prilike i pretvara ih u poduzetničke pothvate. Kirzner (1978) uvodi termin „poduzetnička budnost“, odnosno sposobnost poduzetnika da primijeti neusklađenost cijena unutar ekonomskog sustava i prilika koje su ostale neopažene. Spremnost za preuzimanje rizika također je karakteristika koja se neizostavno veže uz poduzetničko djelovanje. Sklonost preuzimanju rizika definira se kao tendencija pojedinca da preuzme određenu razinu rizika povezanu s poslovnim pothvatom, posebno prilikom donošenja poslovnih odluka (Salleh i Ibrahim, 2011 preuzeto iz Chipeta i Surujlal, 2017). U 18. stoljeću Chantilon razlikuje poduzetnike od ostalih zaposlenika upravo prema spremnosti za djelovanje u neizvjesnosti te za preuzimanje rizika (Gürol i Atsan, 2006). Poduzetnici se suočavaju s rizicima poslovanja, financijskim rizicima ali i sa osobnim rizikom u smislu obiteljskih odnosa i psihičkog zdravlja i sl. (Danso i suradnici, 2016).

Iako se poduzetništvo najčešće spominje u kontekstu malih i srednjih poduzeća ono je ostvarivo u velikim poduzećima, neprofitnim organizacijama, ali i u javnom sektoru. Javni sektor obuhvaća različite institucije i poduzeća kojima upravlja država (Miljenović i suradnici, 2020). U širem smislu čini ga opća država koja obuhvaća tijela središnje države te regionalna i lokalna državna tijela; nefinancijska javna poduzeća koja obuhvaćaju poduzeća u vlasništvu i/ili pod kontrolom države - javna poduzeća te javne financijske institucije - financijska poduzeća u vlasništvu ili pod kontrolom države (Kesner-Škreb, 2006).

Poduzetničko djelovanje u javnom sektoru je moguće ali ono se gotovo marginalizira. Uzrok tome nalazi se u (Demircioglu i Chowdhury, 2021; Kuratko i suradnici, 2011): prirodi javnih institucija i birokratskih struktura koje su nesklone riziku, mehanizmima nagrađivanja i složenosti radnog okruženja koji odvraćaju zaposlenike u javnom sektoru od proaktivnosti, hijerarhijskoj strukturi javnih organizacija ali i ograničenjima u financiranju, utjecaju politike te ograničenom djelovanju menadžera javnog sektora.

Poduzetništvo u javnom sektoru ne može se jednostavno promatrati kroz prizmu korporativnog poduzetništva unatoč zajedničkim karakteristika s velikim poduzećima u privatnom sektoru u smislu hijerarhijske strukture, organizacijske kulture, utvrđenih procedura i pravila, ali ono što razlikuje poduzeća u javnom sektoru od poduzeća u privatnom sektoru su upravo elementi koji otežavaju razvoj poduzetništva u javnom sektoru (Kuratko i suradnici, 2011). Prema Kuratko i suradnicima (2011) glavne razlike od poduzeća u privatnom vlasništvu, odnosno specifičnosti poduzeća u javnom sektoru su sljedeće:

- nisu orijentirani na profit nego ostvarivanje društvenih i političkih ciljeva čiju je uspješnost teže za izmjerit,
- manje su izloženi tržištu i pritisku na troškovnu efikasnost i produktivnost,
- financiraju se iz državnog proračuna i poreznih obveznika,
- teško definiraju svoje kupce / klijente jer služe svrsi više dionika u domeni javnosti,
- poslovanje je predmet interesa javnosti – pritisak na transparentnost i konzultacije sa zainteresiranim skupinama društva u donošenju odluka,
- suočavaju se s kompromisima u smislu preuzimanja rizika/nagrada koji idu snažno u korist izbjegavanja pogrešaka.

Poduzetništvo i javni sektor u literaturi se počinju povezivati 70-ih i 80-ih godina prošlog stoljeća. Poduzetničko ponašanje u javnom sektoru neizravno opisuje Ostrom (1964) prema kojoj „poduzetnik javnog sektora„ inovativnim djelovanjem mijenja tržišno okruženje pokušavajući neizravno utjecati na poželjna ponašanja poduzetnika iz privatnog sektora (Ostrom, 1964 citirano u Hayter i suradnici, 2018).

Leyden i Link (2015) definirali su poduzetništvo javnog sektora kao kreiranje inovativnih javnih politika koje imaju sposobnost generiranja većeg ekonomskog prosperiteta, transformiranjem dosadašnjeg ekonomskog okruženja u ekonomsko okruženje koje pogoduje ekonomskim jedinicama koje moraju biti uključene u kreativne aktivnosti u uvjetima neizvjesnosti. Prema Link (2016) poduzetništvo javnog sektora utječe na transformaciju okruženja prvenstveno povećanjem efektivnosti mreža znanja, kroz povećanje heterogenosti iskustvenih veza između ekonomskih jedinica i sposobnosti tih jedinica da iskoriste tu raznolikost. Kroz političke inicijative u poduzetništvu javnog sektora, omogućava se značajniji tehnološki razvoj, a posljedično i više inovacija u cijelom gospodarstvu (Link, 2016).

Hayter i suradnici (2018) identificiraju tri komponente koje karakteriziraju poduzetništvo javnog sektora:

- inovativne aktivnosti unutar javnog sektora,
- koje mijenjaju postojeći status quo ekonomskog okruženja,
- koje karakterizira neizvjesnost.

Prema Pereira i suradnicima (2019) poduzetništvo javnog sektora obuhvaća čitav niz mjera koje su lokalne, regionalne i nacionalne vlasti usvojile i razvile kako bi podržale poduzetnike u pokretanju vlastitog posla, ali i kako bi im pružile podršku putem razvijenih mreža. Osim toga, ono obuhvaća sve inovativne načine djelovanja javnih vlasti koje promiču gospodarski rast, suradnju s tržištem i građanima u svrhu poticanja održivog razvoja. Kuratko i suradnici (2011) definiraju poduzetništvo u javnom sektoru kao proces kreiranja vrijednosti za građane kroz jedinstvenu kombinaciju javnih i / ili privatnih resursa u cilju iskorištavanja mogućnosti društvenog razvoja. Inovativnost i inovativno djelovanje naglašeno je u svim prikazanim viđenjima poduzetništva javnog sektora.

Korisnici od javnog sektora ne očekuju isključivo stabilnost i pružanje standardnih usluga već i stvaranje pozitivnih promjena (Lackéus i suradnici, 2020).

Poduzetničko djelovanje predstavlja put koji javni sektor može odmaknuti iz statusa quo i učiniti ga aktivnim dionikom u stvaranju poticajnog gospodarskog okruženja tako i liderom u ostvarivanju zadanih energetskih ciljeva.

2.4.1. Problematika zgrada javnog sektora i energetske učinkovitosti s osvrtom na specifičnosti hrvatskog konteksta

U Republici Hrvatskoj fond zgrada javnog sektora obuhvaća gotovo 13,8 milijuna metara kvadratnih korisne površine, a od čega je grijane korisne površine 43,9 % (Fond za zaštitu okoliša i energetsku učinkovitost, n.d.). Gotovo 70 % zgrada izgrađeno je prije 1980. godine i ne zadovoljavaju postojeće energetske standarde (Krstić i Teni, 2018). Prosječna potrošnja toplinske energije takvih zgrada je 220-250 kWh/m^2. U zakonodavstvu Republike Hrvatske nema jedinstvene definicije pojma *Zgrade javnog sektora* te se ono razlikuje s obzirom na namjenu i administrativnu razinu (Vlada Republike Hrvatske, 2017). U tablici 7 prikazan je pregled tumačenja pojma zgrade javnog sektora u zakonodavstvu Republike Hrvatske.

Tablica 7 Pojmovno određivanje zgrada javnog sektora

Zakon o gradnji pročišćeni tekst zakona NN 153/13, 20/17, 39/19, 125/19. Članak 3	„Zgrada javne namjene je zgrada ili dio zgrade koju koristi tijelo javne vlasti za obavljanje svojih poslova, zgrada ili dio zgrade za stanovanje zajednice ili dio zgrade koja nije stambena u kojoj boravi više ljudi ili u kojoj se pruža usluga većem broju ljudi“
Odluka o donošenju Programa energetske obnove zgrada javnog sektora za razdoblje 2016. - 2020., NN 22/2017	„Zgrade centralne države (ministarstva i tijela državne uprave) te zgrade jedinica lokalne i područne (regionalne) samouprave, odnosno zgrade u vlasništvu javnog sektora, u kojima se obavljaju društvene djelatnosti (odgoja, obrazovanja, prosvjete, znanosti, kulture, sporta, zdravstva i socijalne skrbi), djelatnosti državnih tijela i organizacija kao i tijela i organizacija lokalne i područne (regionalne) samouprave, djelatnosti pravnih osoba s javnim ovlastima, zatim zgrade za stanovanje zajednica, zgrade udruga građana i vjerskih zajednica.“
Pravilnik o energetskom pregledu zgrade i energetskom certificiranju, NN 88/17, NN 90/20, NN 01/21, NN 45/21, Članak 7	„Vrste zgrada u cjelini odnosno samostalne uporabne cjeline zgrade za koje se izdaje energetski certifikat određene su prema pretežitoj namjeni korištenja i dijele se na: 1. višestambene zgrade – za koje se u pravilu izrađuje jedan zajednički certifikat, a može se izraditi i zasebni energetski certifikat 2. obiteljske kuće, 3. uredske zgrade, 4. zgrade za obrazovanje, 5. bolnice, 6. hoteli i restorani, 7. sportske dvorane, 8. zgrade trgovine – veleprodaja i maloprodaja, 9. ostale nestambene zgrade koje se griju na temperaturu +18 °C ili višu (npr.: zgrade za promet i komunikacije, terminali, postaje, pošte, telekomunikacijske zgrade, zgrade za kulturno-umjetničku djelatnost i zabavu, muzeji, knjižnice i slično)“
Tehnički propis o racionalnoj uporabi energije i toplinskoj zaštiti u zgradama (NN 128/15, 70/18, 73/18, 86/18, NN 102/20) Članak 4, stavak 1	„Bolnica je zgrada u kojoj se pruža medicinski i kirurški tretman, te njega za bolesne i ozlijeđene osobe, sanatorij, zgrada koja se upotrebljava za rehabilitaciju, veterinarsko liječenje i sl.“ „Uredska zgrada je zgrada koja se upotrebljava u poslovne svrhe, za administrativne i upravne svrhe, npr. banka, poštanski ured, ured lokalne uprave i državnih tijela, sud i sl..“ „Zgrada za obrazovanje je zgrada za predškolsko, osnovno i srednje obrazovanje (npr. jaslice, vrtić, škola), zgrada koja se upotrebljava za više obrazovanje i istraživanje i sl. „Sportska dvorana je zgrada za sportove koji se održavaju u zatvorenom prostoru (košarkaška i teniska igrališta, plivališta, gimnastičke dvorane, dvorane za klizanje i sl.) „Višestambena zgrada je stambena zgrada s četiri ili više stana, stambeni blok, stambena zgrada za stanovanje zajednica (npr. dom umirovljenika, radnički,

	dječji, đački, studentski dom, sirotište, vojarna, zatvor i sl.) zgrada s apartmanima za povremeni boravak i sl.“
Direktiva o energetskoj učinkovitosti	Razlikuje zgrade središnje vlasti i zgrade jedinica lokalne i područne (regionalne samouprave) i javna poduzeća: „Zgrade središnje vlasti su svi administrativni odjeli s nadležnošću na cijelom državnom području države članice.“ „Zgrade jedinica lokalne i područne (regionalne) samouprave, javnih poduzeća te drugih korisnika.“

Izvor: Izrada autora na temelju Odluka o donošenju Programa energetske obnove zgrada javnog sektora za razdoblje 2016. – 2020, NN 22/2017-508

Tumačenje zgrada javnog sektora u dokumentu *Odluke o programu energetske obnove zgrada javnog sektora za razdoblje 2016 – 2020. godine* jasno definira kako administrativnu razinu tako i namjenu zgrade te je u ovom istraživanju dano tumačenje korišteno za definiranje uzorka zgrada javnog sektora.

Na temelju obveza i smjernica koje proizlaze iz *Direktive 2012/27/EU o energetskoj učinkovitosti* predložene od Europskog parlamenta i Vijeća od 25. listopada 2012., Republika Hrvatska je uspostavila zakonodavni okvir vezano uz energetsku učinkovitost u sektoru zgradarstva. Područje energetske učinkovitosti regulirano je kroz brojne zakone i podzakonske akte, a čije je provođenje u ingerenciji Ministarstva gospodarstva i održivog razvoja, Ministarstva prostornoga uređenja, graditeljstva i državne imovine, Ministarstva zaštite okoliša i energetike, Nacionalnog koordinacijskog tijela za energetsku učinkovitost i Fonda za zaštitu okoliša i energetsku učinkovitost.

Zakon o energetskoj učinkovitosti (NN 127/14, 116/18, 25/20, 32/21, 41/21) krovni je Zakon u ovom području kojim se osigurava pravna stečevina Europske unije, odnosno prenosi odrednice koje proizlaze iz *Direktive 2012/27/*EU o energetskoj učinkovitosti. *Zakonom o energetskoj učinkovitosti (NN 127/14, 116/18, 25/20, 32/21, 41/21) „uređuje se područje učinkovitog korištenja energije, donošenje planova na lokalnoj, područnoj (regionalnoj) i nacionalnoj razini za poboljšanje energetske učinkovitosti te njihovo provođenje, mjere energetske učinkovitosti, obveze energetske učinkovitosti, obveze regulatornog tijela za energetiku, operatora prijenosnog sustava, operatora distribucijskog sustava i operatora tržišta energije u svezi s prijenosom, odnosno transportom i distribucijom energije, obveze distributera energije, opskrbljivača energije i/ili vode, a posebice djelatnost energetske usluge, utvrđivanje ušteda energije, te prava potrošača u primjeni mjera energetske učinkovitosti*“ .

Svrha *Zakona o energetskoj učinkovitosti (NN 127/14, 116/18, 25/20, 32/21, 41/21)* je ostvarivanje ciljeva održivog energetskog razvoja:

- smanjenje negativnih utjecaja na okoliš iz energetskog sektora,
- poboljšanje sigurnosti opskrbe energijom,
- zadovoljavanje potreba potrošača energije,
- ispunjavanje međunarodnih obveza Republike Hrvatske u području smanjenja stakleničkih plinova kroz poticanje mjera energetske učinkovitosti u svim sektorima potrošnje energije.

Člankom 21 *Zakona o energetskoj učinkovitost (NN 127/14, 116/18, 25/20, 32/21, 41/21)* je dotaknuta uloga javnog sektora u okviru politike sustavnog gospodarenja energijom i vodom. Propisana je obveza javnog sektora da na energetski učinkovit način upravlja potrošnjom energije i vodom te je u ispunjenju te obveze dužan: "

1. odlukom iz redova vlastitog osoblja ili ugovaranjem prema pravilima o nabavi usluga imenovati osobu odgovornu za energetsku učinkovitost, za dio zgrade na korištenju i /ili vlasništvu ili zgradu ili za više zgrada skupno,
2. redovito pratiti i najmanje jednom mjesečno unositi podatke o potrošnji energije i vode u zgradama ili dijelovima zgrada na korištenju i/ili u vlasništvu ili u kojima se energija plaća javnim sredstvima u nacionalni informacijski sustav za gospodarenje energijom i redovito ažurirati podatke o energetskim svojstvima zgrade,
3. analizirati periodički, a najmanje jednom godišnje, potrošnju energije u zgradama ili dijelovima zgrada na korištenju i/ili u vlasništvu ili u kojima se energija plaća javnim sredstvima, a o čemu izvještava APN,
4. na svim mjernim mjestima potrošnje energije i vode u zgradi, dijelu zgrade ili skupini zgrada čiji je ukupni trošak potrošnje energije i vode jednak ili veći od 700.000,00 kuna ugraditi sustav daljinskog očitavanja potrošnje i povezati ga s nacionalnim informacijskim sustavom za gospodarenje energijom" (Zakon o energetskoj učinkovitosti, NN 127/14, 116/18, 25/20, 32/21, 41/21).

Način upravljanja, analiziranja potrošnje energije i vode propisan je *Pravilnikom o sustavnom gospodarenju energijom u javnom sektoru* (NN 18/15, 06/16). ISGE sustav je sustav putem kojeg javni sektor može upravljati potrošnjom energije i vode te provoditi analizu potrošnje i izvještavati o potrošnji energije i vode (Vlada Republike Hrvatske, 2017). ISGE sustav svakako predstavlja inovativno rješenje kojim javni sektor može pratiti izvršenje obveza preuzetih po

pitanju energetske učinkovitosti u sektoru zgradarstva. Kao glavne funkcionalnosti sustava ističu se (Vlada Republike Hrvatske, 2017):“

- prikupljanje i unos osnovnih podataka o zgradama te kontrola potrošnje energije i vode na mjesečnoj, tjednoj ili dnevnoj razini (mjesečni računi i/ili očitavanje stanja brojila),
- prikupljanje podataka o potrošnji javne rasvjete u gradovima i općinama RH,
- modul za unos energetskih pregleda, certifikata i ostalih EE mjera provedenih na objektu,
- modul praćenja programa Energetske obnove zgrada javnog sektora,
- jednostavan pristup informacijama o ukupno potrošenoj količini energije i vode, načinima i mjestima na koji se energija troši i energentima koji se koriste.
- izračuni i analize s ciljem uočavanja neželjene, prekomjerne i neracionalne potrošnje te identificiranje mogućnosti za ostvarivanje energetskih i novčanih ušteda,
- monitoring i verifikacija ostvarenih ušteda,
- automatizirano upozoravanje o kritičnim događajima i nepravilnostima u radu,
- korisnička sučelja prilagođena pojedinim ulogama u sustavu,
- napredno filtriranje i sortiranje baze podataka,
- izvještaji i različiti grafički prikazi mogu biti prikazani u Excel i PDF formatu, po objektu, grupi objekata ili etiketi,
- pojedinačno uređivanje grupa računa pojedinih distributera,
- pojedinačno uređivanje stavki računa unutar pojedinih grupa računa,
- tablični satni prikaz potrošnje s pametnih mjernih uređaja,
- grafička analiza kroz prikaze apsolutne i relativne potrošnje, E-T krivulja i CUSUM krivulja,
- svakodnevno statističko procesuiranje baze podataka,
- interni sustavi za komuniciranje, pohranu dokumenata i alarmiranje,
- omogućavanje izravnog unosa računa u bazu podataka od strane distributera i opskrbljivača te analitičko praćenje poslanih podataka od strane istih,
- praćenje sesija svakog pojedinog korisnika, kao i grupe korisnika.“

Osim ISGE baze u Republici Hrvatskoj uspostavljen je *Sustav za praćenje, mjerenje i verifikaciju ušteda energije (SMIV)* s ciljem sustavnog praćenja ušteda energije koje proizlaze iz implementacije mjera energetske učinkovitosti, a za upravljanje SMIV sustavom zaduženo je Nacionalno koordinacijsko tijelo za energetsku učinkovitost. *Informacijski sustav*

energetskih certifikata (IEC) uspostavljen je 2017. godine i predstavlja aplikacija koja „omogućuje ovlaštenim osobama za energetsko certificiranje, energetske preglede zgrada i/ili redovite preglede sustava grijanja, sustava hlađenja i sustava ventilacije i klimatizacije u zgradi, izdavanje i pohranu energetskih certifikata i unos podataka o energetskom stanju zgrade“ (Ministarstvo prostornog uređenja, graditeljstva i državne imovine, n.d.).

Iz navedenog proizlaze tri neovisna sustava za praćenje energetske učinkovitosti sektora zgradarstva u Republici Hrvatskoj. Važno je naglasiti da sustavi nisu međusobno povezani. Povezivanje navedenih sustava svakako bi doprinijelo boljoj analizi postojećeg stanja fonda zgrada u Republici Hrvatskoj i upravljanje istim. Agencija za pravni promet i posredovanje nekretninama (APN) zadužena za provođenje programa energetske obnove zgrada javnog sektora dužna je „informirati vlasnike/korisnike zgrada javnog sektora o obvezama koje je Republika Hrvatska preuzela u smislu povećanja energetske učinkovitosti i korištenja obnovljivih izvora energije (OIE) u zgradama javnog sektora, o modelima provedbe energetske obnove, te o raspoloživoj financijskoj pomoći“ (Vlada Republike Hrvatske, 2017). Hodogram aktivnosti u provođenju energetske obnove javnih zgrada definiran *Programom energetske obnove zgrada javnog sektora za razdoblje 2016. – 2020* prikazan je na slici 8.

Slika 8 Provedba programa energetske obnove javnih zgrada (APN, 2020)

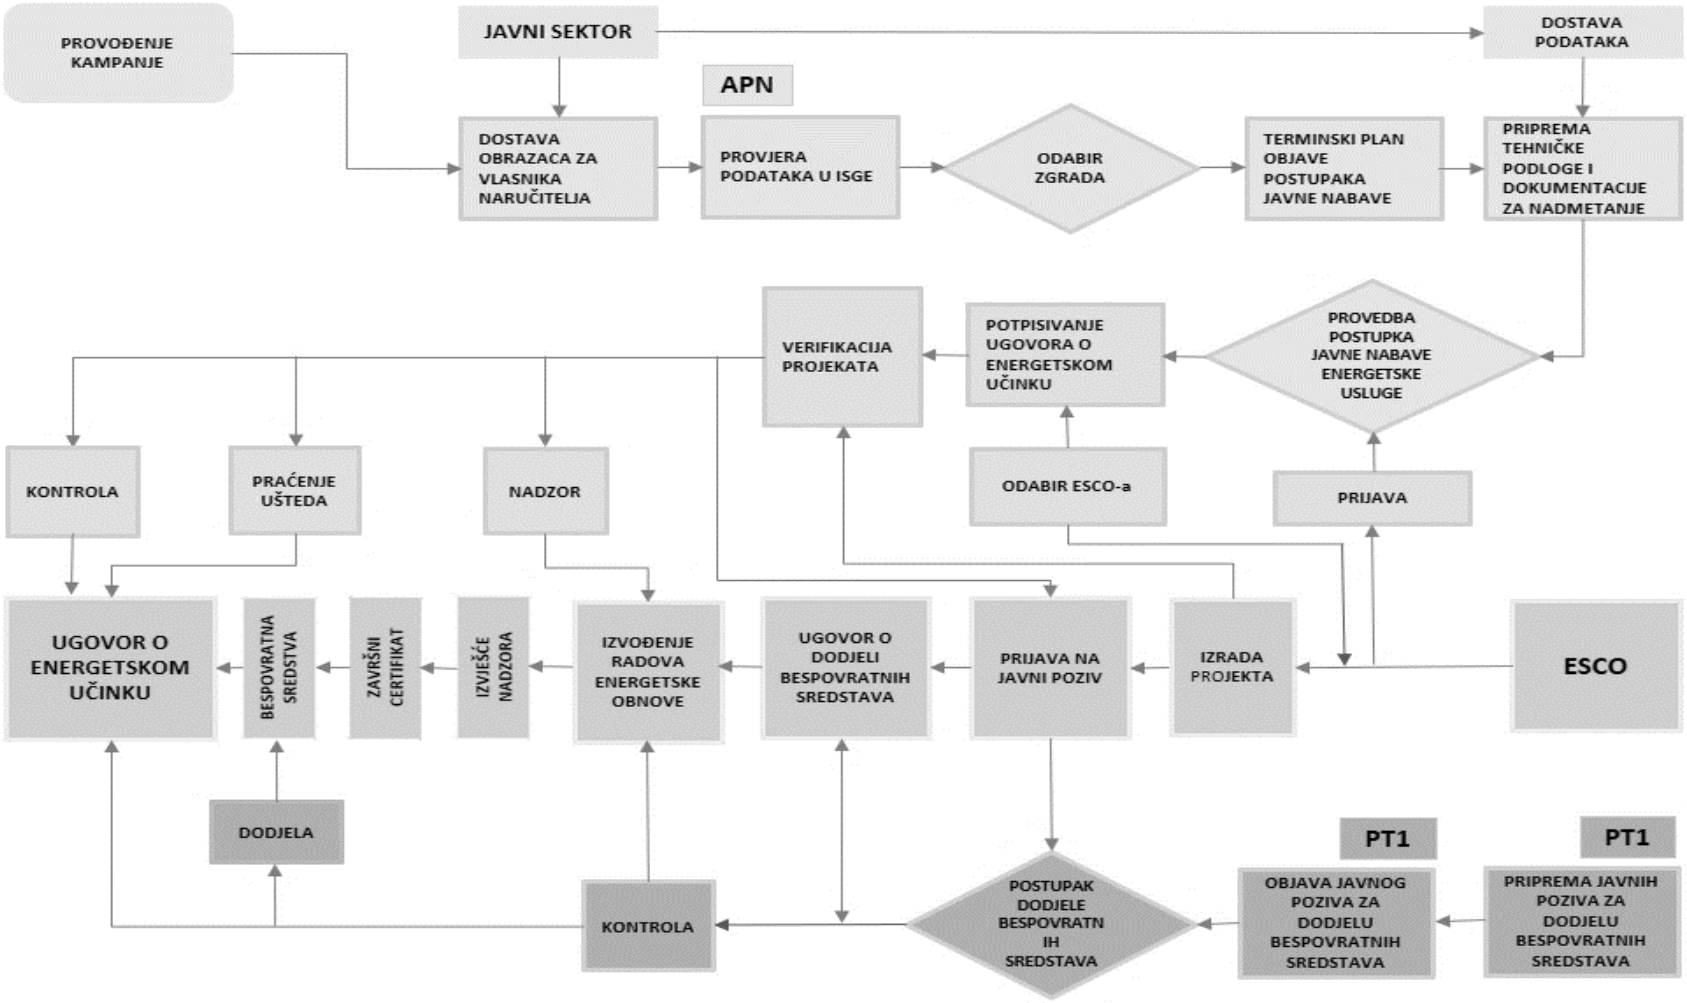

Izvor: Odluka o Programu energetske obnove zgrada javnog sektora za razdoblje 2016. – 2020, Agencija za pravni promet nekretnina

Iz hodograma aktivnosti je vidljivo da se radi o zahtjevnom i dugotrajnom procesu koji počinje prijavom korisnika/ upravitelja u program energetske obnove što dovodi do pitanja prijavljuju li se korisnici svih energetsko neučinkovitih zgrada u programe energetske obnove zgrada. Iz tog razloga, fokus je na prvih nekoliko faza u predstavljenom hodogramu: *„Provođenje kampanje“ – „Javni sektor - Dostava obrazaca za vlasnika naručitelja“ – „APN“ – Provjera podataka u ISGE“ – „Odabir zgrada“*.

Prvi korak je na vlasnicima/korisnicima zgrada javnog sektora. Vlasnici/korisnici zgrada javnog sektora podnose prijave za uključivanje u proces energetske obnove zgrada javnog sektora nakon čega slijedi procedura provjere podataka u ISGE sustavu te odluka o odabiru zgrada koje će se uključiti u programe energetske obnove. Programi energetske obnove zgrada javnog sektora sufinanciraju se sredstvima Europskog fonda za regionalni razvoj. S obzirom da su korisnici/vlasnici obvezni osigurati preostali dio financijskih sredstava za provođenje energetske obnove brojne zgrade javnog sektora se ne uključuju u programe energetske obnove jer nisu u mogućnosti osigurati ostatak financijskih sredstava iz proračuna jedinica lokalne i regionalne samouprave. Nadalje, slaba percepcija korisnika/vlasnika zgrada javnog sektora o energetskom stanju zgrade i nedovoljna informiranost također su razlozi ne prijavljivanja u programe energetske obnove.

Nužno je promijeniti pristup APN-a, odnosno državnog tijela odgovornog za provođenje programa energetske obnove. Aktivnost *„Provođenje kampanje*“ trebala bi se provoditi ciljno tj. APN bi trebao poduzeti inicijativu, primjenom inteligentne potpore za odlučivanje iz ISGE sustava identificirati zgrade s najvećom potrošnjom energije, najlošijim energetskim svojstvima te ciljano pozivati korisnike/vlasnike zgrada javnog sektora na uključivanje u programe energetske obnove. Također, APN bi ih trebao informirati o mogućnostima sufinanciranja, potencijalnim uštedama na troškovima energije i ostalim koristima koje proizlaze iz energetske učinkovitosti i sustavnog upravljanja energijom.

U prethodnom potpoglavlju identificirane su generalne prepreke s kojima se suočava javni sektor na putu ka povećanju energetske učinkovitosti u zgradama. Javni sektor Republike Hrvatske nije iznimka te u provođenju programa energetske obnove zgrada javnog sektora suočen je kako s financijskim tako i pravnim, organizacijskim i društvenim preprekama.

Programom energetske obnove javnih zgrada u razdoblju od 2016. do 2020. identificirane su prepreke u provođenju programa energetske obnove javnih zgrada (tablica 8).

Tablica 8 Prepreke u provođenju programa energetske obnove zgrada javnog sektora

Zakonodavne i pravne	**Financijske prepreke**	**Tehničke, organizacijske i društvene prepreke**
Neusklađenost propisa za provođenje ESCO modela energetske obnove zgrada javnog sektora s drugim propisima.	Nedostatak financijske sposobnosti javnog sektora.	Neadekvatna dokumentacija zgrada javnog sektora.
Tretman javnog duga kod ugovora o energetskom učinku.	Kreditna sposobnost pružatelja energetske usluge.	Praćenje i verifikacija ušteda.
Knjigovodstveni i porezni tretman ugovora o energetskom učinku.	Nevoljkost banaka da financiraju projekte energetske obnove javnih zgrada.	Stav javnog sektora prema energetskoj učinkovitosti.
Nedovoljno tipiziran ugovor o energetskom učinku i dokumentacija za nadmetanje.	Nedostatak garancija.	Nedostatak administrativnih i tehničkih kapaciteta javnog sektora.
Razlika između javno-privatnog partnerstva i ugovora o energetskom učinku.	Manjak adekvatnih, dugoročnih financijskih instrumenata.	/

Izvor: Izrada autora na temelju dokumenta „Odluka o donošenju Programa energetske obnove zgrada javnog sektora za razdoblje 2016. – 2020“. (NN 22/2017-508)

Iz prikazane tablice 8 vidljivo je da prepreke nisu vezane samo uz jednog dionika. Kako bi se svladale prikazane prepreke u energetskoj obnovi javnog sektora potrebno je osigurati suradnju svih dionika u procesu; od korisnika/upravitelja zgrada javnog sektora, provoditelja procesa obnove zgrada javnog sektora, zakonodavca te bankarskog sustava. Veličina javnog sektora u Republici Hrvatskoj svakako doprinosi njegovoj tromosti i indiferentnosti po pitanju energetske učinkovitosti.

Jasno definiranje procedura i smjernica koje će pojasniti tehničke, pravne, financijske, knjigovodstvene i druge elemente ugovora o energetskom učinku te standardizacija ugovora o energetskom učinku i utvrđivanje utjecaja na proračun RH, odnosno proračun jedinica lokalne i regionalne samouprave nameće se kao rješenje financijskih i zakonodavnih prepreka (Vlada Republike Hrvatske, 2017). Zakonodavne prepreke su na zakonodavcu i korisnici/vlasnici javnog sektora nemaju izravan utjecaj na njih. Pojednostavljenje procedura i potpora u

odlučivanju u provedbi programa energetske obnove provoditeljima, donositeljima odluka o odabiru zgrada koje će ući u programe energetske obnove svakako bi pridonio rješavanju brojnih prepreka i bržoj provedbi procesa.

Međutim, ono na što korisnici/vlasnici zgrada javnog sektora mogu izravno utjecati su organizacijske prepreke. Potrebno je osvijestiti korisnike/vlasnike zgrada javnog sektora o pitanju energetske učinkovitosti, o koristima koje bi proizašle povećanjem energetske učinkovitosti, ali i ulozi svakog pojedinog zaposlenika i njihovoj osobnoj odgovornosti naspram ovog pitanja te koristima koje mogu ostvariti. To je moguće postići obrazovanjem, uključivanjem stručnog kadra koji će se ozbiljno i sustavno baviti upravljanjem energijom u zgradama. Nadalje, u javni sektor potrebno je preslikati obrasce poduzetničkog ponašanja i stvoriti okruženje spremno za inovativno djelovanje. Taj je proces kompleksan s obzirom na to da je potrebno pomiriti specifičnosti javnog sektora s poduzetničkim djelovanjem. Međutim, poduzetničko djelovanje predstavlja put kojim se javni sektor može odmaknuti od statusa quo i učiniti ga aktivnim dionikom u stvaranju poticajnog okruženja otvorenog za primjenu inovativnih tehnologija te liderom u provođenju energetskih politika.

Razvoj ISGE sustava predstavlja važan korak u inovativnom djelovanju zakonodavca, odnosno APN, tijela zaduženog za upravljanje energetskom učinkovitošću u Republici Hrvatskoj. Ujedno, daljnji razvoj ISGE sustava može dati golemi doprinos u poticanju inovativnog djelovanju ostalih dionika u javnom sektoru po pitanju potrošnje energije. Kako je već nekoliko puta istaknuto, *Pravilnikom o energetskom pregledu zgrade i energetskom certificiranju (*NN 88/17, NN 90/20, NN 01/21, NN 45/21) propisana je obveza energetskog certificiranja za zgrade javne namjene čija ukupna korisna površina prelazi 250 m^2 te su korisnici/vlasnici zgrada javnog sektora obvezni u ISGE sustav unijeti sve podatke o zgradama. Unatoč obvezi izrade energetskog certifikata za velik broj zgrada javnog sektora taj podatak nije poznat. Takva situacija dovodi do toga da se u konačnici za zgrade javnog sektora koje nemaju izrađen ili upisan energetski certifikat u ISGE sustav ne zna koliko su energetski učinkovite i takve zgrade javnog sektora nalaze se u svojevrsnom statusu quo. Poboljšanjem postojećeg ISGE sustava za upravljanje potrošnjom energije kroz strožu kontrolu unesenih podataka, dodavanje modela za predviđanje potrošnje te inoviranjem procesa provođenja energetske obnove javnih zgrada to se može promijeniti, što će biti predstavljeno u sljedećim poglavljima.

3. METODOLOGIJA RADA

U prethodnom poglavlju predstavljena je važnost energije za rast i razvoj, uloga energetskih certifikata i proračunskih modela te fenomen odstupanja u potrošnji energije (engl. *performance gap*) koji je predmet brojnih znanstvenih istraživanja. Odstupanje u potrošnji energije nije dovoljno istraženo u sektoru zgradarstva u Republici Hrvatskoj. Nameće se i pitanje kako učinkovito gospodariti energijom zgrada javnog sektora i planirati energetsku obnovu istih ako podaci o energetskoj učinkovitosti, odnosno energetskom razredu nisu poznati ili ako postoje značajna odstupanja u stvarnoj potrošnji energije u zgradama u odnosu na proračunske vrijednosti potrošnje iskazane na energetskim certifikatima. Iz toga proizlazi i motivacija za istraživanje performansi postojećih modela, fenomena odstupanja u potrošnji u zgradama javnog sektora u RH, ali i za predlaganje modela koji će se temeljiti na stvarnim performansama zgrade i na taj način inovirati ISGE sustav. Kako bi se odgovorilo na postavljena istraživačka pitanja i dileme u radu su postavljene tri glavne hipoteze koje glase:

H1: Postoje odstupanja između stvarne potrošnje energije i proračunske potrošnje energije iskazane na energetskim certifikatima zgrada javnog sektora.

H2: Model za procjenu potrošnje energije temeljen na strojnom učenju smanjiti će jaz u predviđanju i dati točnije procjene potrošnje energije od postojećih metoda energetskog certificiranja.

H3: Na temelju dobivenog modela mogu se identificirati glavni prediktori potrošnje energije u zgradama javnog sektora koji će se koristiti u svrhu bolje alokacije financijskih resursa u energetsku obnovu zgrada i tako povećati učinkovitost javnog sektora.

U nastavku će se objasniti istraživački pristup, dizajn istraživanja, podaci te korištene metode i tehnike kojima se odgovorilo na istraživačka pitanja, hipoteze i ostvario cilj ove doktorske disertacije.

3.1. Istraživački pristup, dizajn i metode

Jasno definiran istraživački pristup i dizajn ključni su čimbenici za osiguranje pouzdanosti i valjanosti provedenog istraživanja. Johnson i Clark (2006) naglašavaju važnost odabira istraživačke strategije s obzirom na to da ona ima značajan utjecaj kako na shvaćanje predmeta istraživanja i način njegova istraživanja tako i na način razumijevanja istoga (Johnson i Clark, 2006, preuzeto iz Saunders i suradnici, 2019).

Kako bi se osigurala pouzdanost i valjanost provedenog istraživanja, prilikom planiranja istoga koristio se model „istraživačkog luka“ (engl. *Research onion*). Istraživački luk ilustrira načine i metode koje se mogu koristiti u različitim fazama istraživanja s ciljem razvoja konačnog dizajna istraživanja (Saunders i suradnici, 2019). Istraživački luk predstavljen je na slici 9 .

Slika 9 Istraživački luk

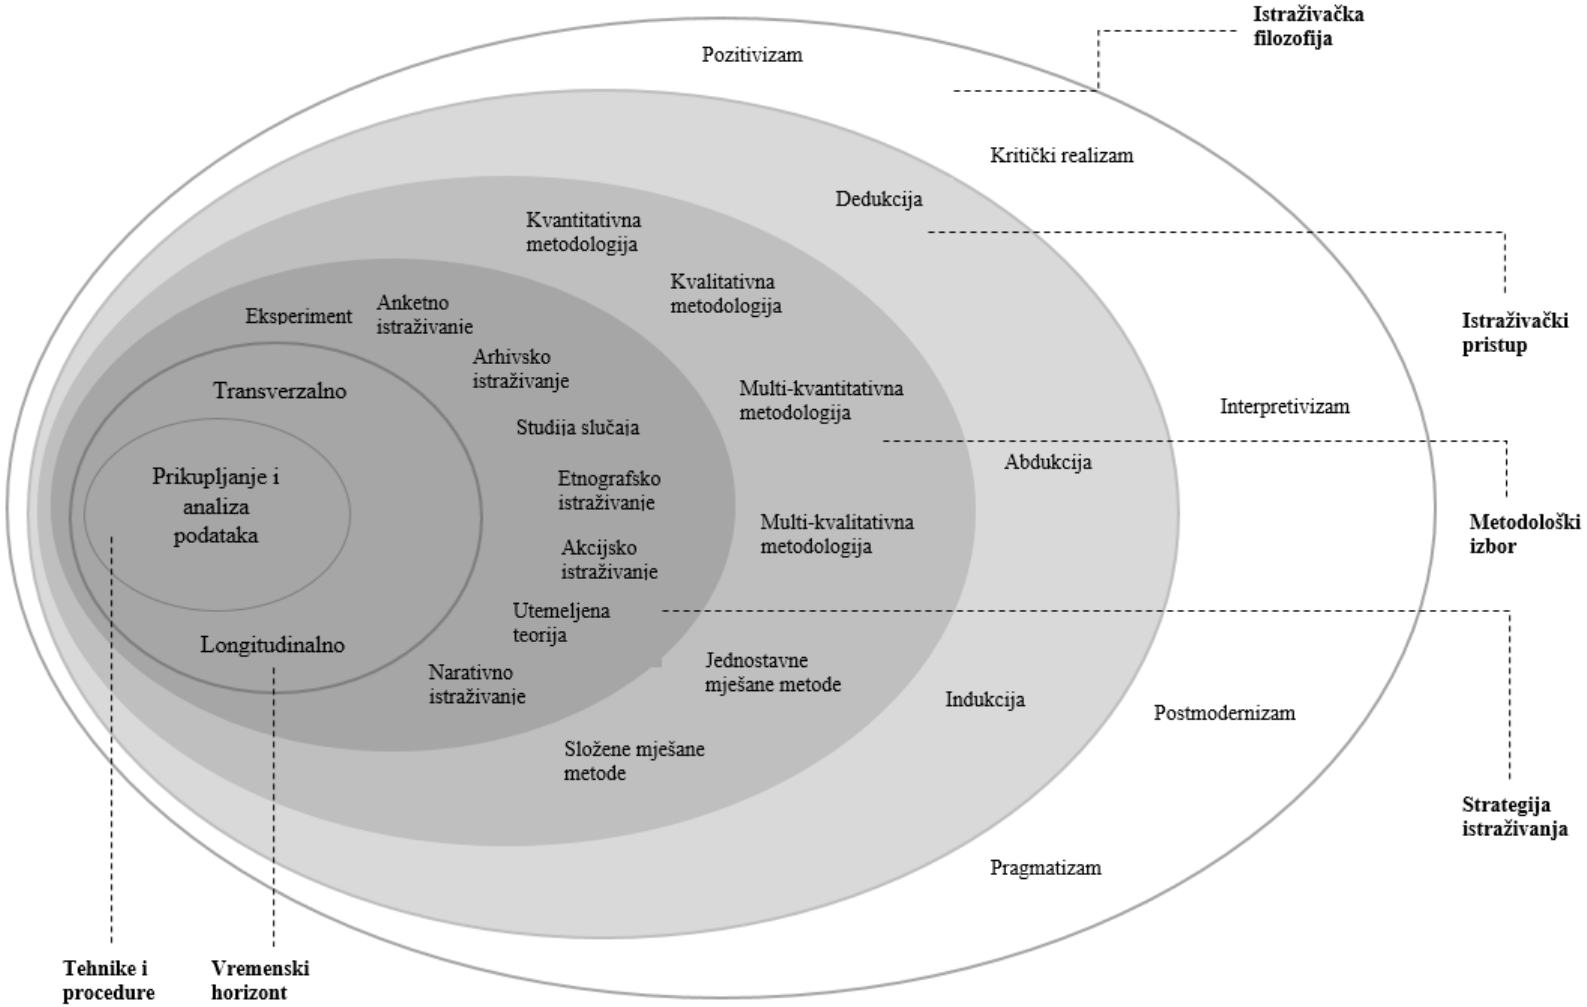

Izvor: Saunders, M., Lewis, P., Thornhill, A. (2019) Research methods for business students, 8th edition. Pearson, London. UK

Istraživački luk prikazan na slici 9 sastoji se od šest glavnih slojeva počevši od istraživačke filozofije do prikupljanja i analize podataka.

U nastavku će se objasniti slojevi istraživačkog luka s naglaskom na elemente korištene u ovoj doktorskoj disertaciji. Prvi sloj obuhvaća istraživačku filozofiju i njime se opisuje skup principa koji se odnose na svjetonazor ili stav iz kojeg se provodi istraživanje. Hitchcock i Hughes (2002) navode kako istraživanje proizlazi iz pretpostavki, odnosno različiti istraživači mogu imati različite pretpostavke o prirodi istine i znanja te njegovom stjecanju. Prema Žukauskas i suradnicima (2018) istraživačka je filozofija osnova istraživanja koja uključuje odabir istraživačke strategije, formuliranje problema, prikupljanje podataka, obradu i analizu podataka. Uobičajeno se promatra sa stajališta epistemologije, ontologije i metoda.

Epistemologija se odnosi na valjane informacije potrebne za istraživanje i kako ih netko može dobiti, odnosno na viđenje prihvatljivog znanja, dok se ontologija odnosi na istraživačevo viđenje prirode stvarnosti (Saunders i suradnici, 2019). U poslovnom istraživanju najčešće se koriste sljedeće istraživačke filozofije: pozitivizam, kritički realizam, interpretatizam, postmodernizam i pragmatizam.

U tablici 9 prikazane su različite istraživačke filozofije sa stajališta ontologije, epistemologije te metode koje se najčešće koriste u poslovnim istraživanjima.

Tablica 9 Prikaz istraživačkih filozofija u poslovnom istraživanju

	Pragmatizam	**Pozitivizam**	**Realizam**	**Interpretatizam**
Ontologija	Vanjski, višestruki pogled izabran kao odgovor na istraživačko pitanje.	Vanjski, objektivni i neovisan o ostalim sudionicima.	Objektivan. Postoji neovisno o uvjerenju ili znanju njihovog postojanja ali se tumači kroz socijalno uvjetovanje .	Subjektivan, višestruka značenja, stalne promjene.
Epistemologija	I uočljivi fenomen i subjektivna značenja mogu pružiti prihvatljivo znanje ovisno o istraživačkom pitanju. Usredotočenost na praktično primijenjeno istraživanje, integriranje različitih perspektiva prilikom tumačenja podataka.	Jedino uočljivi fenomeni mogu pružiti vjerodostojne podatke, činjenice. Usredotočenost na uzročnost i generalizaciju.	Uočljivi fenomeni pružaju vjerodostojne podatke, činjenice. Nedovoljno podataka znači netočnost u tumačenju. Usredotočenost na objašnjavanje u kontekstu.	Subjektivna značenja i društveni fenomeni. Usredotočenost na pojedinosti o situaciji, stvarnost koja stoji u pozadini, subjektivna značenja .
Najčešća metoda istraživanja	Mješoviti ili višestruki istraživački dizajn, kvantitativni i kvalitativni pristup.	Visoko strukturiran, veliki uzorci, mjerenje, kvantitativan, ali može se koristiti i kvalitativni pristup.	Odabrane metode moraju se uklopiti u predmetnu materiju, kvantitativni ili kvalitativni pristup.	Mali uzorci, duboko ispitivanje, kvalitativni pristup.

Izvor: Saunders, M., Lewis, P. i Thornhill, A. (2019) Research methods for business students, 8th edition. Pearson, London. UK - prilagođeno

Istraživačka filozofija u ovoj doktorskoj disertaciji je pozitivizam. Pozitivizam je filozofija znanja, koja se naziva i epistemologija, prema kojoj je samo znanje stečeno izravnim promatranjem činjenično i pouzdano. Pozitivistički pristup temelji se na stvarnoj i objektivnoj interpretaciji podataka kojima se raspolaže (Nel, 2016).

Prema pozitivističkoj filozofiji istraživanja pojave se mogu razumjeti na objektivan način, a istraživač ima ulogu objektivnog analitičara, ograđuje se od osobnih vrijednosti i djeluje samostalno (Žukauskas i suradnici, 2018).

Karakteristično za pozitivističku filozofiju je (Nel, 2016): pozitivisti vjeruju da se znanje može "otkriti" korištenjem znanstvene metode, "otkriveno" znanje omogućuje objašnjenja uzroka stvari koja se događaju u svijetu, naglašava se eksperimentiranje, promatranje, kontrola, mjerenje, pouzdanost i valjanost u procesima istraživanja, podrazumijeva kvantitativni pristup istraživanju, vjeruje da metode znanstvenog istraživanja daju precizne, provjerljive, sustavne i teoretske odgovore na istraživačko pitanje ili hipoteze.

Prema Nel (2016) nedostatak pozitivističke filozofije je: oslanjanje na iskustvo kao valjani izvor znanja, a mnogi osnovni i važni pojmovi poput uzroka, vremena i prostora ne temelje se na iskustvu. Pretpostavlja da se sve vrste procesa mogu percipirati kao određena varijacija djelovanja pojedinaca ili odnosa među pojedincima. Rezultati istraživanja samo su opisni i nedostaje uvid u dubinska pitanja.

Nakon odabira istraživačke filozofije u drugom sloju istraživačkog luka odabire se istraživački pristup koji može biti: deduktivni u kojem istraživanje polazi od teorije prema testiranju teorije, induktivni - u kojem istraživanje polazi od podataka i usmjereno je na stvaranje teorije, te abduktivni u kojem se polazi od prikupljanja podataka s ciljem istraživanja fenomena, otkrivanja tema i istraživanja uzoraka, kako bi se generirala ili unaprijedila teorija, te dodatno testirala kroz prikupljanje novih podataka (Saunders i suradnici, 2019).

Kako bi se odgovorilo na postavljena istraživačka pitanja korišten je deduktivni pristup. Deduktivnim pristupom nastoje se objasniti uzročno-posljedične veze između teorije i varijabli što vodi ka razvijanju hipoteza i najčešće se prikupljaju kvantitativni podaci. Saunders i suradnici (2019) ističu nekoliko specifičnosti deduktivnog pristupa: pouzdanost istraživanja osigurava se primjenom visoko strukturirane metodologije koja omogućava repliciranje, operacionalizacija istraživanih koncepta na način koji omogućuje mjerenje činjenica, često kvantitativno, redukcionizam, odnosno istraživani problem svodi se na najjednostavnije moguće elemente te generalizacija kao još jedna važna specifičnost koja se veže uz odabir uzorka i njegove veličine. U ovoj doktorskoj disertaciji polazište je bilo pregled postojeće literature, istraživanje problematike energetske učinkovitosti zgrada javnog sektora u Republici

Hrvatskoj, nakon čega su definirana istraživačka pitanja, hipoteze, te su prikupljeni su potrebni kvantitativni podaci kako se odgovorilo na postavljena pitanja.

Istraživačka filozofija i istraživački pristup u fokusu su u prva dva sloja istraživačkog luka, dok su na istraživački dizajn fokusirana iduća tri sloja. Istraživačkim dizajnom definira se kako će se istraživačka pitanja pretvoriti u istraživački projekt (Saunders i suradnici, 2019). Treći sloj istraživačkog luka proizlazi iz istraživačkog pristupa i predstavlja metodološki okvir istraživanja. Metodologija istraživanja može biti kvantitativna, kvalitativna, multi-kvantitativna, multi-kvalitativna ili se mogu koristiti mješovite metode (jednostavne ili složene).

Kvantitativno istraživanje najčešće se koristi kao sinonim za bilo koji podatak, tehniku prikupljanja (poput upitnika) ili postupak analize podataka (poput grafikona ili statističke obrade) koja generira ili koristi numeričke podatke. Suprotno tome, „kvalitativno istraživanje“ često se koristi kao sinonim za bilo koju tehniku prikupljanja podataka (poput intervjua) ili analize podataka postupaka (poput kategoriziranja podataka) koji generira ili koristi nenumeričke podatke (Saunders i suradnici, 2019). Kako bi se postigao cilj istraživanja korištena je kvantitativna metodologija: od prikupljanja podataka do testiranja postavljenih hipoteza korištenjem statističkih metoda za obradu podataka te primjenom metoda strojnog učenja za izradu modela za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji primarne energije.

Istraživačka strategija opisana je četvrtim slojem istraživačkog luka i njom se opisuje način provođenja istraživanja. U ovom istraživanju podaci o zgradama javnog sektora prikupljeni su iz ISGE sustava.

Vremenski horizont istraživanja opisuje peti sloj istraživačkog luka, a on može biti longitudinalni ili transverzalni. Istraživanje u ovom radu transverzalno je s obzirom na to da su podaci prikupljeni u jednom trenutku vremena. Šesti sloj istraživačkog luka obuhvaća tehnike i procedure vezane uz prikupljanje i analizu podataka.

Na slici 10 prikazan je istraživački okvir ove doktorske disertacije u kontekstu prethodno opisanih slojeva istraživačkog luka.

Slika 10 Istraživački okvir doktorske disertacije

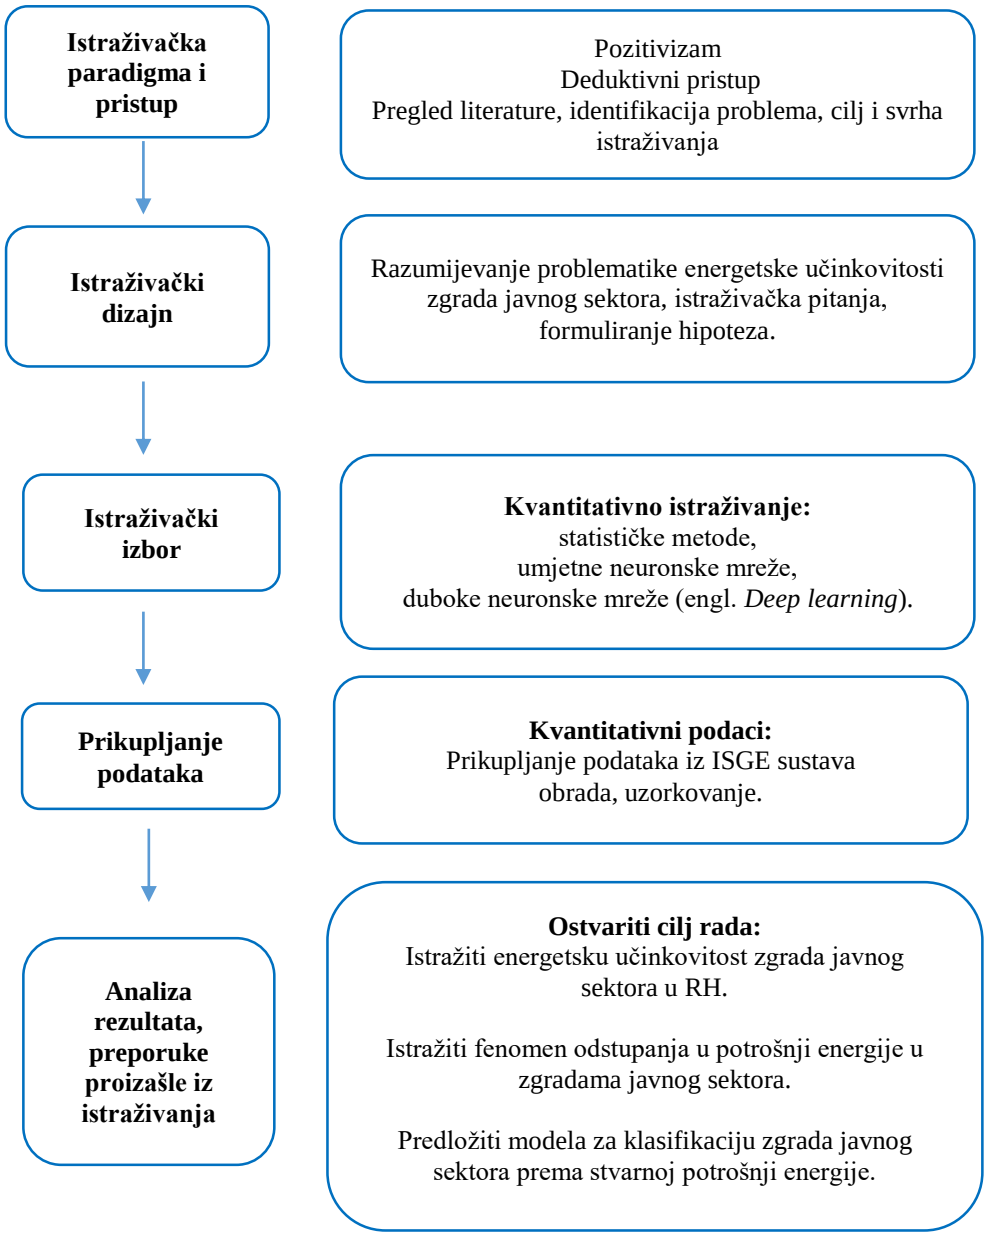

Izvor: Izrada autora

Istraživački dizajn ukazuje na smjer u kojem se razvija doktorska disertacija te predstavlja temelj i plan za provođenje empirijskog istraživanja. Empirijsko istraživanje provedeno je u tri faze koje su prikazane na dijagramu istraživačkog procesa (slika 11).

Slika 11 Dijagram istraživačkog procesa

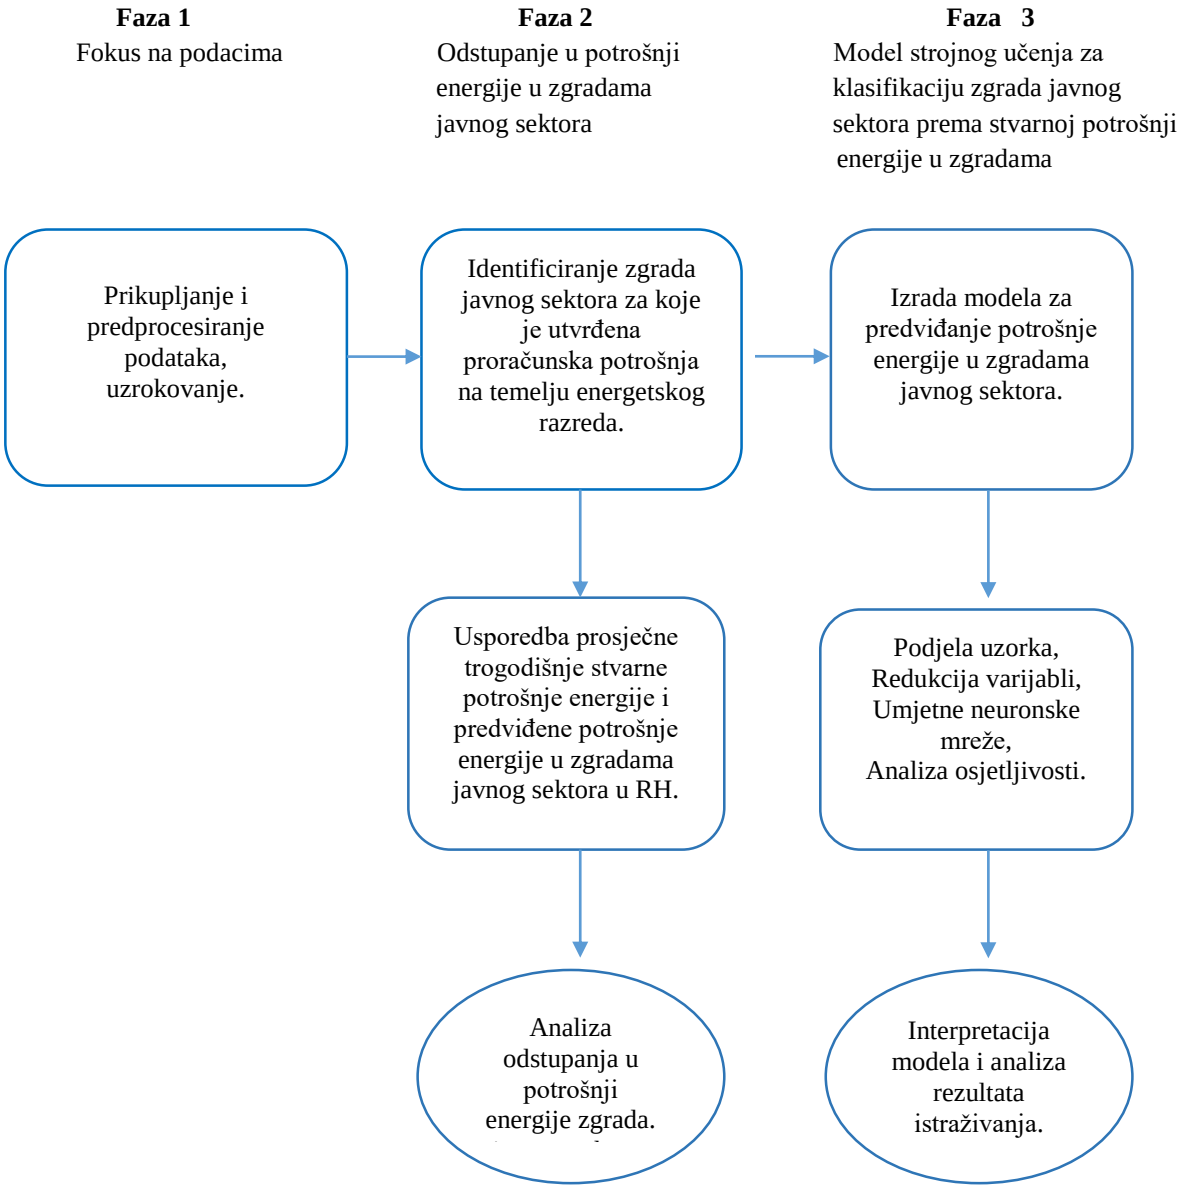

Izvor: Izrada autora

U prvoj fazi istraživanja bavilo se prikupljanjem i pripremom podataka. Ova faza ujedno predstavlja i temelj kvantitativnog istraživanja. Kvalitetni ulazni podaci preduvjet su izradi točnog, vjerodostojnog modela. Nakon pripreme podataka uslijedile su iduće dvije faze istraživanja.

U drugoj fazi istraživanja, istražilo se odstupanje u potrošnji energije zgrada javnog sektora. U ovoj fazi istraživanja iz ukupnog uzorka pripremljenog u prvoj fazi izdvojene su samo one

zgrade javnog sektora za koje je poznata proračunska potrošnja energije, nakon čega je uspoređena sa stvarnom potrošnjom za potrebe toplinske energije.

U trećoj fazi istraživanja izradio se model za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji energije. Za izradu modela korišten je cjelokupan uzorak, sve zgrade javnog sektora kao i njihovi atributi. Zbog značajnog broja varijabli u ulaznom prostoru napravljena je selekcija varijabli na temelju statističkih metoda, nakon čega je uslijedila izrada modela za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji energije temeljena na metodi umjetnih neuronskih mreža.

3.2. Podaci

Podaci korišteni u ovoj disertaciji prikupljeni su u sklopu znanstveno - istraživačkog projekta *Metodološki okvir za učinkovito upravljanje energijom s pomoću inteligentne podatkovne analitike MERIDA* iz ISGE sustava u kojem se prikupljaju podaci o zgradama javnog sektora u Republici Hrvatskoj. U ISGE sustavu zgrade javnog sektora opisane su kroz brojne statičke (opće, konstrukcijske i energetske karakteristike zgrada) i dinamičke podatke (potrošnja energenata na mjesečnoj razini prema dostavljenim računima od dobavljača i potrošnja na tjednoj ili dnevnoj razini prikupljena izravnim očitanjem stanja s brojila) (APN, n.d.).

Iz ISGE sustava preuzeti su sirovi podaci iz nekoliko različitih tablica. U fazi predprocesiranja sve tablice spojene su u jedinstvenu bazu podataka koja je podloga za provođenje daljnjeg empirijskog istraživanja.

3.2.1. Prikupljanje, predprocesiranje i vizualizacija podataka

Nakon preuzimanja podataka iz ISGE sustava uslijedilo je daljnje pretprocesiranje i vizualizacija preuzetih podataka.

Na slici 12 prikazan je način preuzimanja i pripreme podataka za daljnje istraživanje.

Slika 12 Proces prikupljanja podataka

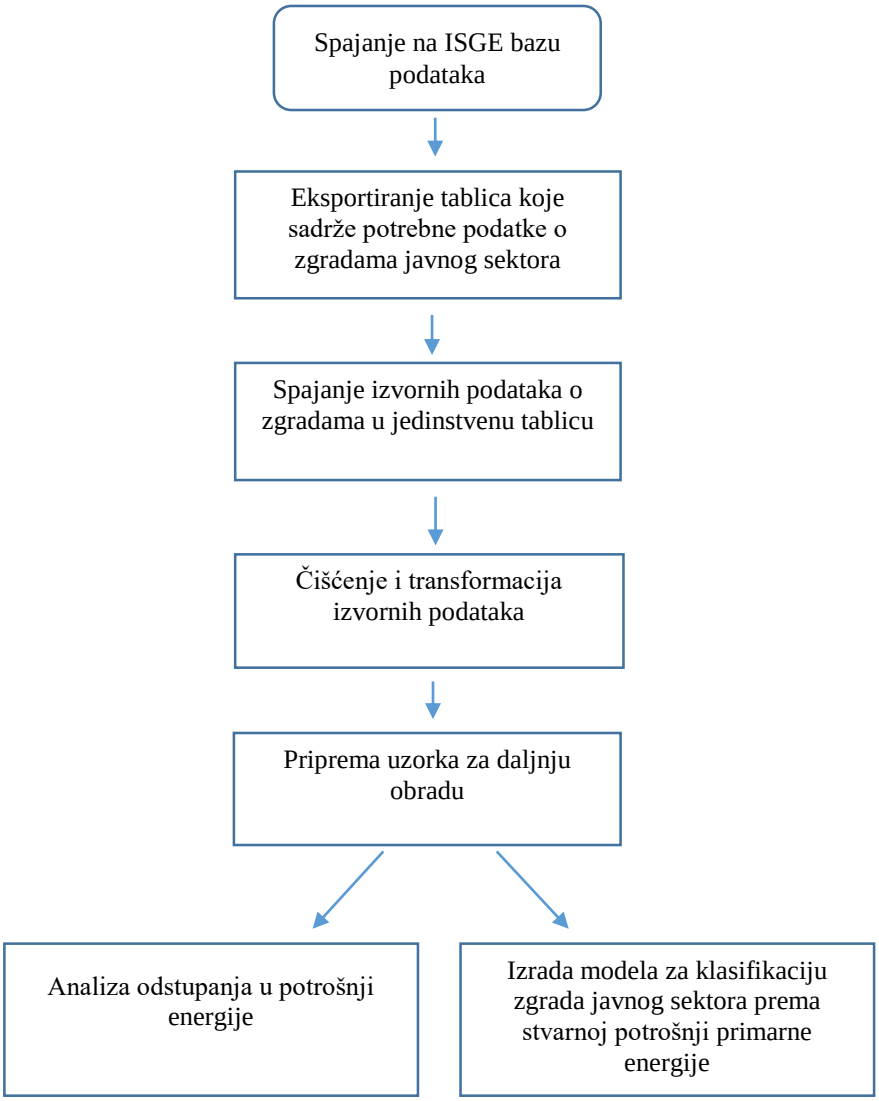

Izvor: Izrada autora

Prvi korak u procesu prikupljanja podataka bilo je povezivanje na bazu podataka ISGE sustava iz koje su preuzeti statički i dinamički podaci o zgradama javnog sektora koji su izvorno zapisani u nekoliko različitih tablica unutar ISGE baze podataka:

- *tablica a* - sadrži sve objekte javne namjene (30217 objekata i 340 varijabli),
- *tablica b* - sadrži dodatne podatke o objektima (14 varijabli),
- *tablica c* - sadrži dodatne konstrukcijske podatke o objektima (11 varijabli),
- *tablica d* - sadrži podatke o mjesečnoj potrošnji energije objekta od 2005. do 2019. godine (11 varijabli).

U prvoj iteraciji radilo se na spajanju izvornih statičkih podataka o zgradama javnog sektora, odnosno istoj zgradi javnog sektora pridruženi su pripadajuće varijable koje se nalaze u prikazanim tablicama (*tablica a, b, c*). U ovom koraku dobivena je nova tablica koja sadržava 30217 zapisa i 365 varijabli u njihovom izvornom obliku. Dobiveni broj zapisa ne predstavlja pojedinačnu zgradu javnog sektora iz razloga što su u preuzetoj bazi ISGE-a konstrukcijski podaci o pojedinoj zgradi javnog sektora zapisani kroz desetke redova, a to su podaci o energetskim karakteristikama vanjske ovojnice - prozirnog i neprozirnog dijela ovojnice.

U idućem koraku napravljena je transformacija podataka te su svi podaci o pojedinačnoj zgradi javnog sektora stavljeni u isti zapis (red u tablici). Na taj način identificirano je ukupno 3836 zgrada javnog sektora koje su opisane kroz 365 atributa. U četvrtoj tablici, odnosno *tablici d* izvorno je prikazana mjesečna potrošnja različitih energenata (struja, plin, voda, briketi) izraženih u kWh u razdoblju od 2005. do 2019. godine. Ovim istraživanjem obuhvaćena je potrošnja svih energenata u zgradama javnog sektora u razdoblju od 2017. do 2019. godine, odnosno prosječna trogodišnja potrošnja energije u navedenom razdoblju. Izvorno, potrošnja energije zapisana je na mjesečnoj razini. Kako bi se dobila godišnja potrošnja za 2017., 2018. i 2019. godinu mjesečna potrošnja u kWh pretvorena je u godišnju potrošnju energije izraženu u kWh za svaku promatranu godinu nakon čega je izračunat trogodišnji prosjek potrošnje za pojedinu zgradu javnog sektora. Prosječna trogodišnja potrošnja energije svedena je na potrošnju energije po m² i kreirana je nova varijabla *Prosječna potrošnja energije kWh/m²*.

Međutim, podatak o stvarnoj potrošnji energije poznat je za 2192 zgrade javnog sektora što je značilo da se iz daljnje obrade isključuju zgrade za koje ovaj podatak nije poznat, odnosno za 1644 zgrade nije bilo podataka o potrošnji energije. Nepostojanje tih vrijednosti odgovornost je korisnika/vlasnika zgrada javnog sektora koji unatoč zakonskoj obvezi ne unose u ISGE sustav podatke o stvarnoj potrošnji zgrada koji su im vidljivi iz mjesečnih računa za potrošnju energije.

U idućoj iteraciji uslijedilo je povezivanje konstrukcijskih podataka zgrada javnog sektora s njihovom stvarnom prosječnom trogodišnjom potrošnjom po m² i izrada uzorka za daljnju obradu. Povezivanjem konstrukcijskih i građevinskih podataka zgrade s pripadajućom stvarnom potrošnjom energije dobiven je uzorak koji uključuje 2192 zgrade javnog sektora.

Nakon spajanja podataka uslijedio je proces čišćenja i daljnja transformacija podataka. U procesu čišćenja podataka prvo su isključene sve varijable koji ne predstavljaju građevinska i

uporabna obilježja zgrada javnog sektora kao što su razni kontakt podaci, atributi koji se odnose na stambene zgrade, podaci o provedenim javnim natječajima, podaci o ugovorima, razne bilješke i slično. Na taj način isključeno je 197 varijabli od 365 varijabli preuzetih iz ISGE sustava u prvoj iteraciji.

Daljnjim uvidom u podatke utvrđene su brojne nedostajuće vrijednosti kao i pogreške nastale prilikom unosa podataka o zgradama javnog sektora u ISGE sustav. Nedostajuće vrijednosti predstavljaju problem prilikom modeliranja s obzirom na to da se mnogi statistički testovi ne mogu izvršiti ako u uzorku postoje nedostajuće vrijednosti. Zamjena nedostajućih vrijednosti predstavljala je veliki problem s obzirom na specifičnost podataka i istraživani problem te odabir imputacijske metode može utjecati na reprezentativnost uzoraka i zaključke u provedenom istraživanju. Isključivanje podataka iz promatranog skupa podataka smatra se tradicionalnim pristupom u upravljanju nedostajućim podacima. Tri su načina na koji se nedostajuće vrijednosti mogu isključiti iz promatranog skupa podataka (Melcher i Silipo, n.d.): mogu se isključiti svi redci u kojima nedostaje jedna ili više vrijednosti metodom brisanja redaka (engl. *Listwise deletion method)*, mogu se isključiti samo oni redci kojima nedostaju vrijednosti u stupcima koji se koriste za analizu i taj proces naziva se *brisanje u paru* (engl. *Pairwise Deletion*), a osim redaka mogu se isključiti i varijable, odnosno stupci koji imaju više nedostajućih vrijednosti od zadanog praga (Melcher i Silipo, n.d.).

Metode za imputaciju nedostajućih vrijednosti razlikuju se u ovisnosti o tipu problema, a sama imputacija može biti pojedinačna ili višestruka. Pojedinačna imputacija uobičajeno se odvija prema tri scenarija: zamjena nedostajućih vrijednosti postojećim vrijednostima (minimalne-maksimalne vrijednosti), zamjena statističkim vrijednostima (srednja vrijednost, mod, medijan) i zamjena predviđenim vrijednostima (regresija) (Melcher i Silipo, n.d.). Metode višestruke imputacije označavaju stvaranje više zamjenskih vrijednosti za pojedinu nedostajuću vrijednost u skupu podataka. Metode višestruke imputacije odvijaju se u tri faze: imputacija podataka, analiza podataka i udruživanje podataka (Chhabra i suradnici, 2017).

S obzirom na značajan broj varijabli te nedostajućih vrijednosti u promatranom skupu podataka u ovom radu u svrhu upravljanja nedostajućim podacima korištena je metoda imputacije podataka te isključivanja nedostajućih podataka. Provjera točnosti podataka te zamjena nedostajućih konstrukcijskih i građevinskih vrijednosti napravljena je prema *Algoritmu obrade i čišćenja podataka o građevinskim i uporabnim karakteristikama zgrada* razvijenom od autora Krstić i Teni (2018) kojim se predlaže postupak zamjene vrijednosti varijabli koje nisu valjane

i/ili nedostaju u skupu podataka. *Algoritam obrade i čišćenja podataka o građevinskim i uporabnim karakteristikama zgrada* je prikazan na slici 13.

Slika 13 Algoritam obrade i čišćenja podataka o građevinskim i uporabnim obilježjima

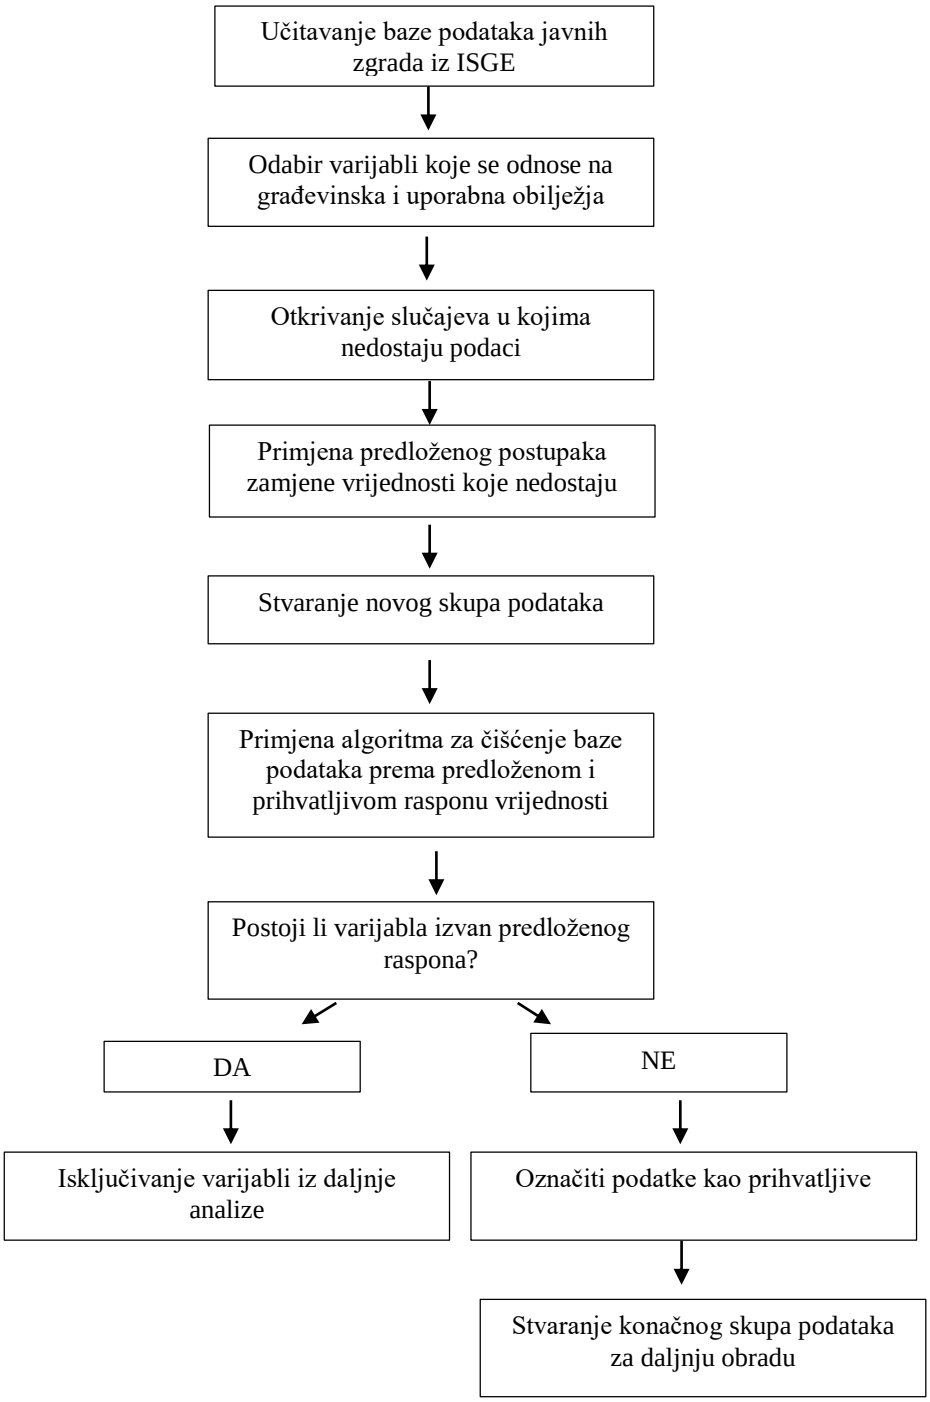

Izvor: Krstić i Teni (2018). Algorithm for constructional characteristics data cleansing of large-scale public buildings database. *WIT Transactions on The Built Environment*, *175*, 213-224.

Prva tri koraka Algoritma predstavljaju identifikaciju konstrukcijskih i uporabnih obilježja zgrade te nedostajućih vrijednosti i vrijednosti izvan mogućih raspona. U četvrtom koraku Algoritma primjenjuje se postupak za zamjenu netočnih ulaznih vrijednosti i/ili nedostajućih vrijednosti, odnosno vrijednost pojedine varijable uspoređuje se s njenim prihvatljivim rasponom vrijednosti. Prihvatljiv raspon vrijednosti za pojedinu konstrukcijsku i uporabnu karakteristiku Krstić i Teni (2018) definirali su na temelju postojećih građevinskih propisa i relevantne literature.

U tablici 10 prikazan je korišten postupak za zamjenu netočnih ulaznih vrijednosti ili nedostajućih vrijednosti za pojedine varijable prema prihvatljivom rasponu vrijednosti definiranima Algoritmom obrade i čišćenja podataka o građevinskim i uporabnim obilježjima.

Tablica 10 Raspon mogućih vrijednosti građevinskih i konstrukcijskih obilježja

Ime varijable	**Raspon u podacima**	**Predloženi postupak zamjene**
Godina izgradnje	od 1917. do 2000 i kasnije	Grupiranje prema godini izgradnje. Godina izgradnje mijenja se prema razdoblju izgradnje: prije 1919., 1919.–1945., 1946.–1970., 1971.–1980., 1981.–1990., 1990.–2000., poslije 2000.
Ukupna ploština neto podne površine grijanog dijela zgrade	0 < Ukupna ploština neto podne površine grijanog dijela zgrade < 100000	Nedostajuće vrijednosti zamijenjene su prema formuli: *Bruto obujam grijanog dijela zgrade kojem je oplošje A [m³] *0,32.* Iz uzorka su isključene sve zgrade (zapisi) kod kojih je vrijednost manja od 50 m².
Ploština bruto podne površine zgrade [m²]	1< Ploština bruto podne površine zgrade [m²] < 100000	Nedostajuće vrijednosti zamijenjene su prema formuli: *Ukupna ploština neto podne površine grijanog dijela zgrade /0,8*. Iz uzorka su isključene sve zgrade (zapisi) kod kojih je vrijednost manja od 50 m².
Bruto obujam grijanog dijela zgrade kojem je oplošje A [m³]	Bruto obujam grijanog dijela zgrade kojem je oplošje A [m³] > Ukupna ploština neto podne površine grijanog dijela zgrade x 2,20	Nedostajuće vrijednosti zamijenjene su prema formuli: *Ukupna ploština neto podne površine grijanog dijela zgrade/0,32*. Iz uzorka su isključene sve zgrade (zapisi) kod kojih je vrijednost manja od 15 m².
Unutarnja projektna temperatura u sezoni grijanja [°C]	16°C < Unutarnja projektna temperatura u sezoni grijanja [°C] < 28°C	Nedostajuće vrijednosti i nule zamijenjene su s vrijednostima propisanima u tablici *Unutarnje proračunske temperature* kojima je propisana

		temperatura ovisno o tipu zgrade (Algoritam za proračun potrebne en. za grijanje i hlađenje prema HRN EN 13790).
Faktor oblika zgrade (F_o)	$0,05 \leq F_o \leq 1,86$	Nedostajuće vrijednosti te vrijednosti izvan intervala zamijenjene su sa srednjom vrijednošću intervala - 0,95.
Specifična godišnja potrebna toplinska energija za grijanje nestambene zgrade, $Q'_{H,nd,ref}$ [kWh/m³a]	$15 \leq Q'_{H,nd,ref} \leq 700$	Nedostajuće vrijednosti i vrijednosti izvan intervala isključene su iz uzorka jer ih nije moguće izračunati niti zamijeniti drugom vrijednošću.
Najveća dopuštena godišnja potrebna toplinska energija za grijanje nestambene zgrade, $Q'_{H,nd,dop}$ [kWh/m³a]	$0 \leq Q'_{H,nd,dop} \leq 130,89$	Nedostajuće vrijednosti i vrijednosti izvan intervala zamijenjene su vrijednostima propisanim nacionalnim propisima. Maksimalne vrijednosti propisane su Tehničkim propisom o racionalnoj upotrebi energije i toplinske izolacije u zgradama, ovisno o klimatskoj zoni.
Udio ploštine prozora u ukupnoj ploštini pročelja, f [%]	0 < Udio ploštine prozora u ukupnoj ploštini pročelja, f [%] < 100	Nedostajuće vrijednosti i vrijednosti izvan intervala isključene su iz uzorka jer ih nije moguće izračunati niti zamijeniti s drugom vrijednošću. U ovom slučaju vrijednost 0 implicira da zgrada nema niti jednog otvora.

Izvor: Izrada autora - prilagođeno prema Krstić i Teni (2018). Algorithm for constructional characteristics data cleansing of large-scale public buildings database. *WIT Transactions on The Built Environment, 175*, 213-224.

Nakon zamjene nedostajućih vrijednosti te vrijednosti koje su izvan zadanog intervala identificirane su konstrukcijske i građevinske varijable koje imaju više od 70 % nedostajućih vrijednosti. To su varijable čije nedostajuće vrijednosti nije bilo moguće zamijeniti prethodno opisanom procedurom. Od ukupno 168 varijabli kod 102 varijabli zabilježeno je više od 70 % nedostajućih vrijednosti. Varijable koje imaju više od 70 % nedostajućih vrijednosti isključene su iz izrade modela strojnog učenja za klasifikaciju zgrada javnog sektora. Ovim je završena procedura spajanja i čišćenja građevinskih i uporabnih podataka.

Konačan skup varijabli dobiven kroz proces pripreme podataka i koji je korišten u empirijskom dijelu istraživanja prikazan je tablici 11.

Tablica 11 *Pregled varijabli i deskriptivna statistika* radi preglednosti nalazi se u prilogu.

Uzorak sadrži velik broj varijabli koje se odnose na konstrukcijske podatke, geografske podatke, podatke o korisnicima i namijeni, podatke o grijanju i hlađenju, meteorološke podatke, podatke o energetskoj učinkovitosti, potrošnji energije te troškovima energije što ukupno čini 69 varijabli kojima su opisane zgrade javnog sektora. Za sve varijable napravljena je i deskriptivna statistika. U konačnom skupu podataka mogu se uočiti i tri varijable koje imaju više od 70 % nedostajućih vrijednosti: *Specifična godišnja potrebna toplinska energija za grijanje nestambene zgrade,* $Q'_{H,\ nd,\ ref}$ *[kWh/m³a], Relativna vrijednost godišnje potrebne toplinske energije za grijanje za nestambene zgrade,* $Q'_{H,\ nd,\ ref}$ *[%]* te *Godišnja potrebna toplinska energija za grijanje* $Q_{H,\ nd,\ ref,}$ *[kWh/a]* koje predstavljaju energetska svojstva zgrade. Navedene varijable nisu isključene iz skupa podataka jer su nužne za pripremu poduzorka za istraživanje odstupanja u potrošnji energije između postojećeg modela za energetsko certificiranje i stvarne potrošnje energije.

Velik broj nedostajućih vrijednosti u navedenim varijablama ukazuje da su za manji broj zgrada javnog sektora poznati podaci iz energetskih certifikata jer te vrijednosti moguće je unijeti u ISGE sustav samo na temelju podataka koji su generirani od strane energetskog certifikatora i iskazane su na energetskom certifikatu. Napravljena deskriptivna statistika ukazuje na to da postoji i velik raspon između minimalnih i maksimalnih vrijednosti pojedinih varijabli te su kod pojedinih varijabli primijećena veća odstupanja između srednje i prosječne vrijednosti. Uzrok tomu počiva u heterogenosti zgrada u promatranom uzorku i nesimetričnost distribucija pojedinih varijabli. Uzorak obuhvaća zgrade koje mogu biti samostalne cjeline, pojedini dijelovi zgrada, ali i zgrade koje su dijelovi kompleksa što znači da su uzorkom obuhvaćene i manje zgrade kao što su škole ali i npr. kompleksi bolnica.

Na temelju deskriptivne statistike može se zaključiti da prosječna primarna potrošnja energije zgrada javnog sektora iznosi 166,88 kWh/m². U prosjeku, promatrane zgrade javnog sektora u uporabi su 5,97 radnih dana u tjednu, prosječno 10,05 radnih sati po danu. Ploština bruto podne površine zgrade u promatranom uzorku prosječno iznosi 1981,50 m² dok je maksimalna ploština bruto podne površine zgrade 71104 m².

Kada se promatra unutarnja projektna temperatura u sezoni grijanja vidljivo je da je maksimalna temperatura 25°C dok je prosječna temperatura 20,31°C u promatranim zgradama javnog sektora. Kada se promatra namjena zgrada, od ukupno 2192 zgrade javnog sektora njih

su 60,13 % obrazovnog karaktera, zatim slijede administrativne zgrade (23,27 %) te zdravstvene ustanove (6,13 %), dok su u najmanjem postotku zastupljeni vojni objekti, odnosno 0,78 % (tablica 12).

Tablica 12 Zgrade javnog sektora prema namjeni

Zgrada javnog sektora	Frekvencija	Postotak (%)
Administrativne zgrade	510	23,27
Zgrade namijenjene kulturi	49	2,24
Zgrade za obrazovanje	1318	60,13
Zgrade opće namjene	38	1,73
Zgrade socijalne namjene	109	4,97
Vojni objekti	17	0,78
Zdravstvene ustanove	151	6,89
Ukupno	**2192**	**100**

Izvor: Izrada autora

U promatranom uzorku, u kontinentalnoj Hrvatskoj nalazi se 72,81 % zgrada javnog sektora, dok se u primorskoj Hrvatskoj nalazi 27,19 % zgrada javnog sektora (tablica 13).

Tablica 13 Zgrade javnog sektora prema regiji

Regija	Frekvencija	Postotak (%)
Kontinentalna Hrvatska	1596	72,81
Primorska Hrvatska	596	27,19
Ukupno	**2192**	**100**

Izvor: Izrada autora

Na slici 14 prikazan je udio zgrada javnog sektora sa svojstvom kulturnog dobra. U uzorku se nalazi 12 % zgrada javnog sektora sa svojstvom kulturnog dobra.

Slika 14 Zgrade javnog sektora kao dio kulturne baštine

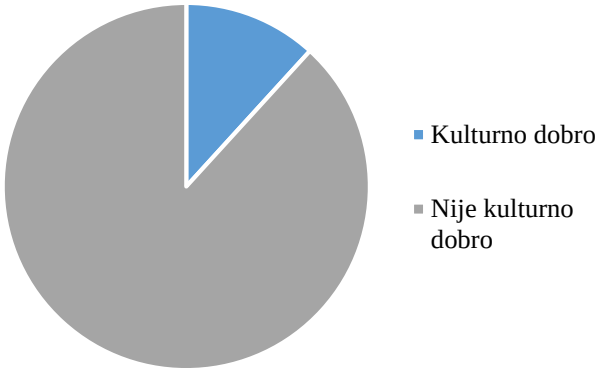

Izvor: Izrada autora

Na slici 15 prikazane su zgrade javnog sektora prema razdoblju izgradnje.

Slika 15 Razdoblje izgradnje zgrade javnog sektora

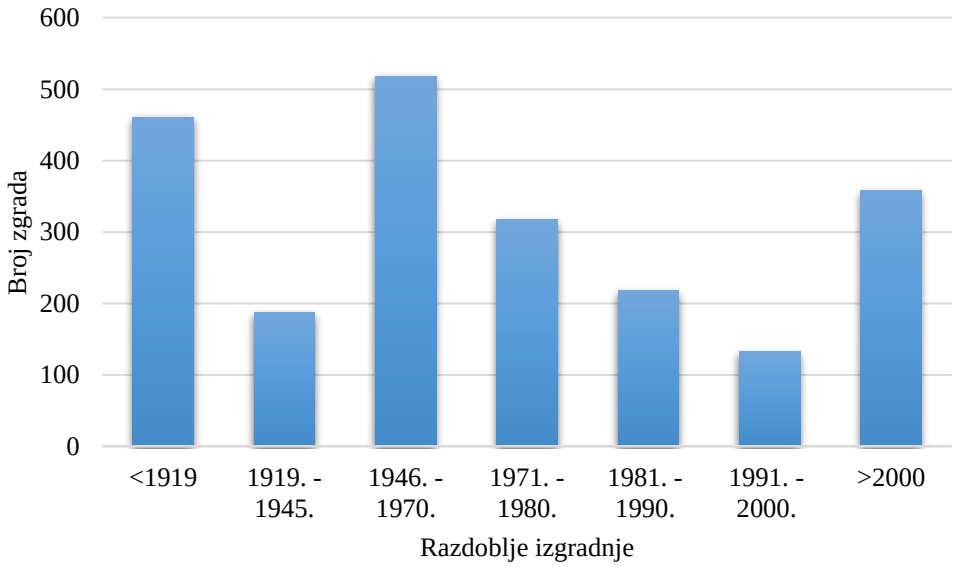

Izvor: Izrada autora

U razdoblju prije 1919. godine izgrađeno je 21,03 % zgrada javnog sektora dok je od 1919. do 1945. godine izgrađeno 8,53 % zgrada javnog sektora u promatranom uzorku. Najveći broj zgrada javnog sektora izgrađen je u razdoblju od 1946. do 1970. godine, odnosno 23,63 %, dok je od 1971. do 1980. godine izgrađeno 14,46 % zgrada javnog sektora. Od 1981. do 1990. godine izgrađeno je 9,95 % zgrada javnog sektora. Razdoblje u kojem je izgrađeno najmanje javnih zgrada jest od 1991. do 2000. godini, odnosno 6,07 % zgrada javnog sektora. U promatranom uzorku 16,33 % zgrada izgrađeno je nakon 2000. godine.

Kada se promatra starost fonda zgrada javnog sektora u Republici Hrvatskoj može se uočiti da je gotovo 77,79 % zgrada javnog sektora sagrađeno prije 1990. godine. S obzirom na starost fonda zgrada javnog sektora važno je promotriti i rekonstrukciju zgrada javnog sektora (tablica 14)

Tablica 14 Rekonstrukcija zgrada javnog sektora

Obnova zgrade javnog sektora nakon 2012 godine	**Frekvencija**	**Postotak (%)**
Da	117	5,34
Ne	2075	94,66
Ukupno	**2192**	**100**

Izvor: Izrada autora

U promatranom uzorku na 5,34 % zgrada javnog sektora izvršena je rekonstrukcija nakon 2012. godine.

U tablici 15 prikazan je broj zaposlenih u zgradama javnog sektora. U promatranom uzorku 68,43 % zgrada javnog sektora broji do 50 zaposlenika, između 50 do 100 zaposlenika ima 18,11 % zgrada javnog sektora dok preko 100 zaposlenih broji 13,46 % zgrada javnog sektora.

Tablica 15 Broj zaposlenih u zgradama javnog sektora

Broj zaposlenih u zgradama javnog sektora	**Frekvencija**	**Postotak (%)**
>50	1500	68,43
50 - 100	397	18,11
<100	295	13,46
Ukupno	**2192**	**100**

Izvor: Izrada autora

Osim broja zaposlenih u zgradama javnog sektora važno je i promotriti broj korisnika (učenika, bolesnika, klijenata) zgrada javnog sektora.

U promatranom uzorku, 23,81 % zgrada javnog sektora koristi do 50 korisnika, između 51 i 150 korisnika koristi 22,95 % zgrada javnog sektora. U uzorku je identificirano 17,15 % zgrada javnog sektora koje broje između 151 i 300 korisnika, dok 14,10 % zgrada javnog sektora koristi od 301 do 550 korisnika. Preko 550 korisnika koristi 21,99 % zgrada javnog sektora (tablica 16).

Tablica 16 Broj korisnika u zgradama javnog sektora

Broj zaposlenih u zgradama javnog sektora	**Frekvencija**	**Postotak (%)**
≤50	522	23,81
51 - 150	503	22,95
151 - 300	376	17,15
301 - 550	309	14,10
> 550	482	21,99
Ukupno	**2192**	**100**

Izvor: Izrada autora

Relativna vrijednost godišnje potrebne toplinske energije za grijanje za nestambene zgrade, odnosno energetski razredi, polazište je prilikom planiranja energetske obnove stambenih i nestambenih zgrada. Međutim, unatoč obvezi energetskog certificiranja za velik broj javnih zgrada ovaj podatak nije poznat ili podaci iz energetskih certifikata korisnici nisu unijeli u ISGE. U promatranom uzorku relativna vrijednost godišnje potrebne toplinske energije za grijanje za nestambene zgrade poznata je za 579 zgrada javnog sektora (26,41 %) što jasno ukazuje na problem prilikom planiranja energetske obnove i potrebu za razvoj modela za klasifikaciju zgrada javnog sektora prema potrošnji energije (tablica 17).

Tablica 17 Energetski certifikat u zgradama javnog sektora

Energetski certifikat u zgradama javnog sektora	**Frekvencija**	**Postotak (%)**
Da	579	26,41
Ne	1613	73,59
Ukupno	**2192**	**100**

Izvor: Izrada autora

Konačan uzorak ovog istraživanja broji 2192 zgrade javnog sektora te značajan broj varijabli (69) kojima su opisane zgrade javnog sektora. Dobiveni uzorak služit će za izradu modela za klasifikaciju zgrada javnog sektora prema stvarnoj primarnoj potrošnji energije. Model je temeljen na metodi umjetnih neuronskih mreža. Umjetne neuronske mreže u ovom radu odabrane su zbog svojih karakteristika: imaju mogućnost obrade velikog broja podataka, uče na prošlim podacima i uočavaju skrivene veze u podacima, imaju sposobnost generalizacije ali i robusnost zbog koje su uspješne u procesiranju podataka sa smetnjama, nedostajućim vrijednostima te ne pretpostavljaju normalnost podataka (KrishnaKumar, 2021; Abiodun i suradnici, 2018; Aggarwal, 2018; Wu i Feng, 2018).

3.3. Metodologija umjetnih neuronskih mreža

Umjetne neuronske mreže metoda su strojnog učenja koja je inspirirana radom ljudskog mozga i procesom učenja koja danas zahvaljujući brzom razvoju informacijsko-komunikacijskih tehnologija i generiranju velike količine podataka uživa izuzetnu popularnost i neizostavan je dio brojnih alata prediktivne analitike. Povijest neuronskih mreža duga je gotovo 80. godina i može se podijeliti u nekoliko razdoblja: od 1950. do 1980. razdoblje početnog istraživanja i razvoja neuronskih mreža; od 1980-tih do 2000. procvat istraživanja u području neuronskih mreža te od 2000. do 2010. godine usmjerenost na neuronske mreže s dubokim učenjem (Kurenkov, 2020).

Ideja o umjetnim neuronskim mrežama datira iz 1940. godine kada su McCulloch i Pitts iznijeli ideju o kombiniranju višeprocesnih elemenata obrade u mrežu, dok je prvu jednoslojnu neuronsku mrežu pod nazivom Perceptron razvio Frank Rosenblatt 1958. godine (Walczak, 2018). Tijekom 60-tih godina prošlog stoljeća istraživanja o neuronskim mrežama bila su na svom vrhuncu. No do prekretnice u istraživanju neuronskih mreža dolazi 1969. godine kada su Minsky i Papert u svojoj knjizi *Perceptron* kritizirali i dokazali ograničenja u radu jednoslojne neuronske mreže što je u konačnici dovelo da pada interesa za daljnje istraživanje umjetnih neuronskih mreža (Walczak, 2018).

Kao odgovor na nedostatke jednoslojne neuronske mreže 1974. godine Paul Werbos razvija višeslojnu perceptron mrežu, uvodi učenje u skrivenom sloju neuronske mreže (Walczak, 2018). Do ponovnog uspona u istraživanjima neuronskih mreža dolazi 1986. godine nakon što su Rumelhart, Hinton, Williams predstavili algoritam s povratnim postupkom (engl. *Backpropagation algorithm*) i usavršili višeslojnu perceptron mrežu (engl. *Multiple layer perceptron*) (Walczak, 2018). Istraživanja u području umjetnih neuronskih mreža nastavljena su i razvijene su brojne umjetne neuronske mreže koje se razlikuju po topologiji, tipu učenja, vezama između ulaznih i izlaznih podataka i sl..

Novo razdoblje u razvoju neuronskih mreža započelo je 2006. godine objavom rada pod nazivom „*A fast learning algorithm for deep belief nets*“ autora Hinton, Osindero i Teh (2006) u kojem je predstavljen algoritam za brzo učenje neuronskih mreža. Rad se smatra svojevrsnom prekretnicom i početkom dubokog učenja (engl. *Deep learning*). Neuronske mreže s više slojeva nisu bile novost, već se i ranije smatralo da ih se ne može dobro istrenirati i kao takve nisu davale dobre rezultate. Iz tog razloga, ideja da se neuronske mreže s više slojeva uistinu mogu dobro istrenirati, ako se ponderi inicijaliziraju na pametan način, a ne nasumce, bila je svojevrsna prekretnica i početak novih istraživanja u području neuronskih mreža (Kurenkov,

2020). Ideja koja se nalazi iza inicijalizacija pondera na pametan način jest zapravo treniranje jednog po jednog sloja s nenadgledanim učenjem (koji počinje s ponderima umjesto samo davanjem slučajnih vrijednosti), a zatim završava s krugom nadziranog učenja, kao što je to uobičajeno za umjetne neuronske mreže (Kurenkov, 2020).

Walczak (2018) opisuje umjetne neuronske mreže kao model koji imitira biološku neuronsku mrežu koristeći smanjeni skup koncepata iz biološkog živčanog sustava. U biološkom živčanom sustavu neuron zauzima središnju ulogu, na isti način središnju ulogu u konceptu neuronskih mreža zauzima umjetni neuron. U biološkom živčanom sustavu biološki neuron putem dendrita prima ulazni impuls nakon čega se taj impuls prevodi preko aksona i pretvara u izlaz, a informacije se šalju putem sinapsi do svih neurona s kojima je neuron povezan (Ujević Andrijić, 2019). Na sličan način djeluje i umjetni neuron: svaka ulazna varijabla $(x_1, \mathrm{x}_2, \dots, \mathrm{x}_\mathrm{n})$ množi se s težinskim faktorima w_i te njihov zbroj predstavlja novu vrijednost koja se primjenom određene aktivacijske funkcije (prijenosne funkcije) transformira u određeni rang 0, +1 ili -1 i šalje kao izlaz drugim neuronima (Finlay, 2014). Težina veze *w* predstavlja snagu veze između dva neurona (Zekić-Sušac, 2000).

Iz prethodno navedenog može se uočiti da umjetne neuronske mreže djeluju u slojevima. Prvi sloj (engl. *input layer*) predstavlja ulazne vrijednosti, odnosno ulazne varijable $(x_1, \mathrm{x}_2, \dots, \mathrm{x}_\mathrm{n})$. Drugi sloj predstavlja skriveni sloj (engl. *hidden layer*) umjetnih neuronskih mreža u kojem svaki neuron prima sumu svih ponderiranih ulaza. Kada pojedini neuron prima ulaz iz prethodnog sloja, vrijednost njegovog ulaza računa se prema ulaznoj funkciji – sumacijskoj funkciji (Zekić-Sušac, 2000). Sumacijska funkcija prikazana je u nastavku:

$$ulaz_i = \sum_{j=1}^{n}(w_{ji} * izlaz_j) \tag{2}$$

Sumacijska funkcija za neuron *i* određena je množenjem izlaza poslanog od strane neurona *j* prema neuronu *i* (označenom kao $izlaz_j$) s težinom veze između neurona *i* i neurona *j*, te sumiranjem tog umnoška za sve neurone *j* povezane s neuronom *i*, a *n* predstavlja broj neurona u sloju koji šalje svoj izlaz primljen od strane neurona *i* (Zekić-Sušac, 2000). $Ulaz_i$ nekog neurona *i* suma je svih vaganih izlaza koji pristižu u taj neuron (Zekić - Sušac, 2018).

Svaki neuron skrivenog sloja prima sumu svih ponderiranih ulaza te primjenjuje se aktivacijska funkcija kako bi se dobio izlaz neurona skrivenog sloja (Zekić - Sušac, 2018):

$$y_c = f\left(\sum_{i=1}^{n} w_i x_i\right) \tag{3}$$

gdje y_c predstavlja izlaz mreže, a f predstavlja aktivacijsku funkciju. Aktivacijskom funkcijom transformira se ulazna vrijednost neurona (Walczak, 2018). Moguće je primijeniti različite aktivacijske funkcije kao što je *step funkcija, sigmoidna funkcija, tvrda sigmoidna funkcija, tangens – hiperbolička funkcija, ReLu funkcija* (engl. *Rectified linear unit*) te druge nelinearne funkcije.

Treći sloj umjetnih neuronskih mreža predstavlja izlazni sloj umjetnih neuronskih mreža. Ovaj sloj predstavlja konačan rezultat umjetnih neuronskih mreža, a koji je posljedica obrade koju su izvodili neuroni u prethodnim slojevima (Buscema i suradnici, 2018). Uspješnost modela umjetne neuronske mreže ocjenjuje se izračunom odstupanja stvarnog izlaza od izračunatog izlaza mreže, odnosno cilj je kreirati model koji će generirati što manju grešku. Metrike za ocjenu uspješnosti ovise o modelu. Ako se radi o regresijskom modelu koristi se (Skansi, 2018): *srednja kvadratna greška (MSE), suma kvadrata (SSE), srednje apsolutno odstupanje (MAD), korijen srednje kvadratne pogreške (RMSE) i prosječna apsolutna postotna pogreška (MAPE).* Klasifikacijski modeli ocjenjuju se metrikama: stopa točnosti klasifikacije (engl. *Accuracy*), matrica konfuzije (engl. *Confusion matrix*), pokazatelj preciznost (engl. *Precision*), pokazatelj odaziva (engl. *Recall*), F1 ocjena (engl. *F1 score*) te AUC (engl. *Area under ROC curve*) (Skansi, 2018).

Matrica konfuzije daje uvid u omjer između broja predviđenih slučajeva i ukupnog broja slučajeva, ali i dublji uvid u odnos između klasa te je temelj izračuna ostalih metrika (Skansi, 2018). Ilustrativni prikaz matrice konfuzije prikazan je na slici 16.

Slika 16 Ilustrativni prikaz Matrice konfuzije

		Predviđeno	
		Pozitivni	**Negativni**
Stvarno	**Pozitivni**	Stvarno pozitivni	Lažno pozitivni
	Negativni	Lažno negativni	Stvarno negativni

Izvor: Izrada autora prema Skansi, S. (2018) Introduction to Deep Learning From Logical Calculus to Artificial Intelligence. Springer

Prilikom tumačenja matrice konfuzije važno je razlikovati nekoliko pojmova (Skansi, 2018) :

- Stvarno pozitivni (engl. *true positive*): Slučajevi u kojima je klasifikator predvidio DA, a stvarni je rezultat također bio DA (ispravna klasifikacija),
- Stvarno negativni (engl. *true negative*): Slučajevi u kojima je klasifikator predvidio NE, a stvarni je rezultat također bio NE,
- Lažno pozitivni (engl. *false positive*): Slučajevi u kojima je klasifikator predvidio DA, a stvarni je rezultat bio NE,
- Lažno negativni (engl. *false negative*): Slučajevi u kojima je klasifikator predvidio NE, a stvarni je rezultat bio DA.

Točnost matrice konfuzije može se izračunati uzimajući prosjek vrijednosti koje leže preko "glavne dijagonale" matrice (Skansi, 2018):

$$\text{Točnost}=\frac{\text{Stvarno pozitivni}+\text{Stvarno negativni}}{\text{Ukupan uzorak}} \tag{4}$$

Pojednostavljeno, predstavlja omjer između broja točnih predviđenih slučajeva i ukupnog broja slučajeva. Stopa točnosti klasifikacije dobar je pokazatelj uspješnosti kada je zastupljenost slučajeva po klasama ravnomjerna. U suprotnom može se dogoditi da je ukupna točnost modela visoka, ali da pojedine klase (koje su manje zastupljene) imaju nisku stopu točnosti. S obzirom na to da u ovoj doktorskoj disertaciji istraživane klase nisu jednako zastupljene ukupna stopa točnosti klasifikacije neće se uzimati kao glavno mjerilo uspješnosti modela. Osim točnosti, na temelju matrice konfuzije izračunavaju se pokazatelji preciznosti, odaziva te F1 ocjena.
Pokazatelj preciznosti stavlja u odnos stvarno pozitivne slučajeve s ukupnim brojem predviđenih pozitivnih slučajeva od strane klasifikatora (Skansi, 2018):

$$\text{Preciznost}=\frac{\text{Stvarno pozitivni}}{\text{Stvarno pozitivni}+\text{Lažno pozitivni}} \tag{5}$$

Odaziv je pokazatelj koji u odnos stavlja broj ispravno klasificiranih pozitivnih slučajeva od strane klasifikatora s ukupnim brojem svih pozitivnih slučajeva (Skansi, 2018):

$$\text{Odaziv}=\frac{\text{Stvarno pozitivni}}{\text{Stvarno pozitivni}+\text{ Lažno negativni}} \tag{6}$$

Kao balans između pokazatelja preciznosti i odaziva nameće se pokazatelj F1 ocjene. F1 ocjena kao pokazatelj predstavlja harmonijsku sredinu pokazatelja preciznosti i opoziva (Vani i Rao, 2019):

$$\text{F1 ocjena} = 2 * \frac{1}{\frac{1}{\text{preciznost}} + \frac{1}{\text{odaziv}}} \tag{7}$$

Raspon za F1 ocjenu je [0, 1], a pokazatelj ukazuje na to koliko je precizan klasifikator (koliko slučajeva ispravno klasificira), kao i koliko je robustan (ne propušta značajan broj instanci). Što je veći rezultat F1, odnosno bliže 1, to su bolje performanse modela (Mishra, 2018).

Iz definicije umjetnih neuronskih mreža može se iščitati još jedna važna karakteristika ove metode, a to je sposobnost učenja iz podataka. Prema paradigmi učenja razlikuje se nadgledano učenje (engl. *Supervised learning*), nenadgledano učenje (engl. *Unsupervised learning*) te učenje s podrškom (engl. *Reinforcement learning*) (Bengio i suradnici, 2017).

Nadgledano učenje podrazumijeva da su izlazne vrijednosti u procesu treniranja neuronske mreže poznate, dok kod nenadgledanog učenja izlazne vrijednosti podataka na kojima mreža trenira nisu poznate (Bengio i suradnici, 2017). Učenje s podrškom posredni je oblik prethodnih tipova učenja. Dongare i suradnici (2012) definiraju učenje umjetnih neuronskih mreža procesom kojim se težinski koeficijenti (engl. *weight)* i odstupanje (engl. *bias*) neuronske mreže prilagođavaju kroz kontinuirani proces simulacija od okoline u kojoj se mreža nalazi.

Prilikom jednog prolaza informacije kroz neuronsku mrežu generira se vrijednost koja se uspoređuje sa stvarnom vrijednošću te se na temelju razlike između stvarne i izračunate vrijednosti (greške) korigiraju težinski koeficijenti prema odabranom pravilu učenja (Ujević Andrijić, 2019). Pravilom učenja određuje se način prilagodbe težinskih koeficijenta, odnosno pravilo učenja predstavlja formulu koja se upotrebljava za prilagođavanje težinskih koeficijenata među neuronima (w_{ij}) (Zekić-Sušac, 2000). Kao najčešće korištena pravila učenja izdvajaju se (Zekić-Sušac, 2000):

- Delta pravilo (Widrow/Hoff-ovo pravilo),
- Poopćeno Delta pravilo,
- Delta-Bar-Delta i Prošireno Delta-Bar-Delta pravilo,
- Kohonen-ovo pravilo (koristi se za nenadgledane mreže).

Delta pravilo ima za cilj minimizirati ciljnu funkciju određivanjem vrijednosti težinskih koeficijenata. Cilj je minimizirati sumu kvadrata grešaka, gdje je greška definirana kao razlika između izračunatog i stvarnog izlaza nekog neurona za dane ulazne podatke (Zekić-Sušac, 2000). Formula Delta pravila prikazana je u nastavku (Zekić-Sušac, 2000):

$$\Delta w_{ij} = \eta * \ y_{cj} * \varepsilon_i \tag{8}$$

Δw_{ij} predstavlja vrijednost prilagođavanja težinskog koeficijenta od neurona *j* prema neuronu *i* izračunatom prema:

$$\Delta w_{ji} = w_{ji}^{nova} - w_{ji}^{stara} \tag{9}$$

y_{cj} predstavlja vrijednost izlaza izračunatog u neuronu *j*, ε je sirova greška izračunata prema:

$$\varepsilon_i = y_{ci} - y_{di} \tag{10}$$

η predstavlja koeficijent učenja, a y_{di} je željeni (stvarni) izlaz koji se upotrebljava za izračunavanje greške.

Problem koji se često pojavljuje u modeliranju neuronskih mreža je pretreniranje mreže (engl. *overfitting*). Nakon predugog treniranja mreža postaje izvrsna u obradi podataka iz skupa za treniranje dok na podacima na kojima nije učila ne pokazuje dobre rezultate, odnosno gubi svojstvo generalizacije (Ying, 2019).

Pretreniranje umjetne neuronske mreže može se spriječiti primjenom određenih metoda i tehnika kao što su (Ying, 2019):

- *Pojednostavljenje modela,* odnosno smanjenje složenosti uklanjanjem slojeva ili smanjenjem broj neurona. Pri tome je važno izračunati ulazne i izlazne dimenzije različitih slojeva koji su uključeni u neuronsku mrežu. Ne postoji općenito pravilo o broju neurona i slojeva.

- *Povećanje podataka* s ciljem smanjenja prekomjernog učenja prilikom treninga modela, odnosno model ne može prenaučiti sve primjere. Broj podataka može se povećati dodavanjem novih slučajeva ali i augmentacijom, umjetnim povećavanjem pomoću tehnika kojima se mogu dodati podaci neznatno izmijenjenih kopija već postojećih podataka ili novostvorenih sintetičkih podataka iz postojećih podataka.

- *Rano zaustavljanje* (engl. *Early Stopping*) predstavlja tehniku regularizacije koja omogućuje određivanje broja epoha treninga i zaustavljanje treninga kada se izvedba modela prestane poboljšavati na skupu podataka za validaciju modela, odnosno izvedba modela poboljšava se do određene točke. Međutim, nakon te točke, greška se modela na testnom uzorku pogoršava, a greška na uzorku za treniranje nastavlja se smanjivati i upravo to ukazuje da je došlo do pretreniranja mreže i potrebno je zaustaviti daljnje treniranje modela.

- *Regularizacija* (engl. *Regularization*) tehnika je kojom se smanjuje kompleksnost modela. Regularizacijom L2 pokušava se smanjiti mogućnost prekomjerne prilagodbe modela održavanjem vrijednosti pondera i odstupanja malim, odnosno da teže prema nuli. Drugim riječima, L2 regularizacija kažnjava velike težine.

- *Isključivanje* (engl. *Dropout*) Tijekom treniranja, u svakoj iteraciji nasumično se zanemaruju pojedini neuroni u mreži. Zanemarivanje nasumičnih neurona ekvivalentno je treniranju različitih neuronskih mreža što pomaže u smanjenju mogućnosti za pretreniranja mreže.

Prethodno su spomenuti skupovi podataka za treniranje, testiranja i validaciju modela umjetne neuronske mreže. Prije izrade modela umjetnih neuronskih mreža uzorak se dijeli na tri dijela za svaku pojedinu fazu rada neuronskih mreža, a to je faza treniranja, faza unakrsne validacije te faza testiranja. U fazi treniranja mreža uči na prošlim slučajevima i ujedno ova faza ima najdulje trajanje, provodi se u tisućama iteracija na istom uzorku. Međutim, rezultat dobiven u fazi treniranja nije mjerilo uspješnosti modela umjetne neuronske mreže. Nakon treniranja dolaze faze unakrsne validacije i testiranja. Ovisno o korištenom alatu, mreža se testira u jednoj od ove dvije faze na podacima na kojima ranije nije učila i taj se rezultat uzima kao mjerilo uspješnosti mreže.

Model umjetne neuronske mreže čine neuroni povezani u slojevima (Finlay, 2014). Umjetne neuronske mreže razlikuju se i prema svojoj arhitekturi ali u suštini one mogu biti dvoslojne neuronske mreže, višeslojne mreže te neuronske mreže s dubokim učenjem. Najčešće korištene arhitekture neuronskih mreža u dosadašnjim istraživanjima su: višeslojne perceptron neuronske mreže (engl. *Multi-layer perceptrons-MLP*), mreže s povratnim vezama (engl. *Recurrent neural network*), konvolucijske neuronske mreže (engl. *Convolutional Neural*

Networks), Kohonenove samoogranizirajuće mreže (engl. *Kohonen Self-Organizing feature map)* te neuronske mreže s dubokim učenjem (engl. *Deep learning neural network*).

Odabir arhitekture neuronske mreže najčešće ovisi o tipu problema koji se modelira. U nastavku će biti pojašnjene *višeslojne perceptron neuronske mreže* i *neuronske mreže s dubokim učenjem* s obzirom na to da je razvoj jedne i druge arhitekture označio svojevrsnu prekretnicu u smjeru istraživanja neuronskih mreža te su obje arhitekture korištene u empirijskom dijelu rada.

3.3.1. Višeslojna perceptron neuronska mreža

Višeslojna neuronska mreža jedna je od najčešće korištenih arhitektura umjetnih neuronskih mreža radi svoje uspješnosti u rješavaju različitih tipova realnih problema (Lillicrap i suradnici, 2020; Wang i suradnici, 2020; Rana i suradnici, 2018). Posebnost ove arhitekture neuronske mreže u tome je što je prva neuronska mreža u kojoj je uvedeno učenje u skrivenom sloju, ali i učenje pomoću algoritma s povratnim postupkom (engl. *Backpropagation algorithm*) kojima su prevladani nedostaci prvih neuronskih mreža. Strukturu *višeslojne neuronske mreže* čine ulazni sloj, izlazni sloj i najmanje jedan skriveni sloj.

Prema Zekić-Sušac (2000) tijek podataka kroz višeslojnu perceptron neuronsku mrežu može se opisati kroz nekoliko koraka“:

1. *od ulaznog sloja prema skrivenom sloju*: ulazni sloj učitava podatke iz ulaznog vektora *X* te ih šalje u prvi skriveni sloj,
2. *u skrivenom sloju*: jedinice u skrivenom sloju primaju vagani ulaz i prenose ga u idući skriveni ili u izlazni sloj koristeći aktivacijsku funkciju,
3. kako informacije putuju kroz mrežu, računaju se sumirani ulazi i izlazi za svaku jedinicu obrade,
4. *u izlaznom sloju:* za svaku jedinicu obrade, računa se skalirana lokalna greška koja se upotrebljava u određivanju povećanja ili smanjenja težina,
5. *propagiranje unazad od izlaznog sloja do skrivenih slojeva:* skalirana lokalna greška, te povećanje ili smanjenje težina računa se za svaki sloj unazad, krenuvši od sloja neposredno ispod izlaznog sve do prvog skrivenog sloja, te se težine podešavaju“.

Računanje u *višeslojnoj perceptron neuronskoj mreži* prikazano je na slici 17.

Slika 17 Računanje u Višeslojnoj perceptron mreži

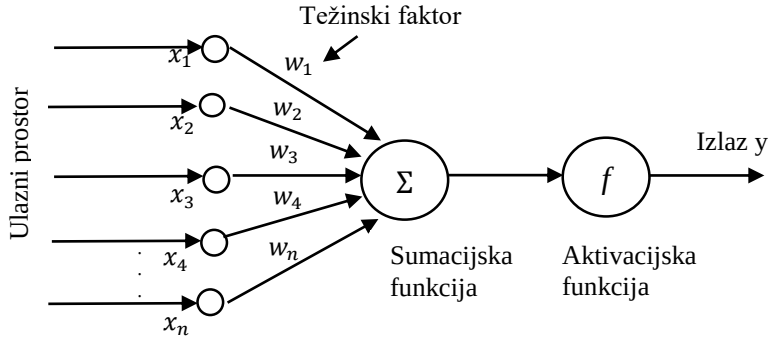

Izvor: Zekić-Sušac, M. (2017). Machine Learning in Energy Consumption Management. U *Proceedings of the 14th International Symposium on Operational Research in Slovenia, Bled*, 7-17.

Proces počinje s ulaznim slojem koji reprezentira ulaz u model, odnosno sastoji se od neurona koji predstavljaju ulazne vrijednosti. Iz ulaznog sloja šalju se vrijednosti u prvi skriveni sloj, svaka ulazna vrijednost množi se s težinskim faktorima *w* (Zekić-Sušac, 2017).

Vrijednost njegovog ulaza računa se prema ulaznoj sumacijskoj funkciji što znači da svaka jedinica skrivenog sloja prima vagani ulaz iz ulaznog sloja. Kako bi se dobio izlaz iz skrivenog sloja primjenjuje se nelinearna aktivacijska funkcija *f*. U slučaju nekoliko skrivenih slojeva, aktivacijska funkcija upotrebljava se kroz sve skrivene slojeve sve dok se ne dostigne izlazni sloj (Zekić-Sušac, 2017). Aktivacijske funkcije razlikuju se prema načinu na koji djeluju nad ulaznim skupom podataka te o njihovom odabiru ovisi brzina učenja, a često i preciznost i performanse neuronske mreže (Kramberger i suradnici, 2019).

Nadalje, izračunava se izlaz mreže y_c koji se zatim uspoređuje sa stvarnim izlazom y_a, a njihova razlika predstavlja lokalnu grešku ε (Has i Zekić-Sušac, 2017). Greška se zatim koristi za podešavanje težinskih faktora u ulaznom sloju prema jednom od pravila učenja, kao što je primjerice ranije spomenuto Delta pravilo:

$$\Delta w_{ij} = \eta * \ y_{cj} * \varepsilon_i \tag{11}$$

gdje je Δw_{ij} razlika između stare i nove težine, η je koeficijent učenja, ε_i je greška neuronske mreže (Has i Zekić-Sušac, 2017).

Cilj je modela neuronske mreže minimizirati grešku, a procesom učenja umjetne neuronske mreže greška predviđanja može se smanjiti. Proces učenja odnosi se na minimizaciju funkcije

gubitka (engl. *Loss Function*). Funkcija gubitka izračunava grešku između željenih rezultata i rezultata neuronske mreže. Ovisno o tipu problema koji se rješava moguće ju je podijeliti u dvije skupine: regresijskog i klasifikacijskog gubitka (Kramberger i suradnici, 2019). Najpoznatije su funkcije gubitka: srednja kvadratna greška (engl. *Mean squared error*), očekivani gubitak (engl. *Likelihood loss*), logaritamski gubitak (engl. *Log loss*), unakrsna entropija (engl. *Cross entropy loss*) (Liang i suradnici, 2018). Nakon računanja greške izračunavaju se gradijenti kako bi se odredio smjer u kojem treba mijenjati vrijednosti težina i propagirati ih po neuronskoj mreži pomoću algoritma s povratnim postupkom, odnosno algoritma za širenjem pogreške unazad (Kramberger i suradnici, 2019).

Algoritam za širenjem pogreške unazad jedan je od najpoznatijih i najučinkovitijih metoda za učenje višeslojnih mreža (Bašić i suradnici, 2008). Predstavlja algoritam koji se koristi kako bi se izračunali gradijenti koji su potrebni za podešavanje težinskih faktora u neuronskoj mreži (Kramberger i suradnici, 2019). Algoritam za širenjem pogreške unazad služi za izmjenu težinskih koeficijenata pomoću metode gradijentnog spusta s ciljem minimiziranja funkcije gubitka. U umjetnim neuronskim mrežama gradijent je potrebno izračunati kako bi se odredio smjer greške i koje je težinske koeficijente potrebno namjestiti kako bi se unaprijedilo rješenje mreže (Kramberger i suradnici, 2019), a proces izračuna se kreće unatrag kroz mrežu. Razvijeni su različiti algoritmi za učenje (optimizaciju) neuronske mreže i izračun gradijenta. Neki od njih su: gradijentni spust (engl. *Gradient descending*), Newtonova metoda, konjugirani gradijent (engl. *Conjugate gradient*), Quasi-Newtonove metode te Levenberg-Marquardtov algoritam.

Gradijentni spust jedan je od temeljnih i najjednostavnijih algoritama učenja (optimizacije) umjetne neuronske mreže (Ruder, 2016). Djeluje u dva koraka, prvo se izračunava smjer učenja za gradijentni spust te se u drugom koraku računa odgovarajuća stopa učenja. Stopa učenja predstavlja broj koji određuje veličinu koraka prema minimumu funkcije ali taj broj ne smije biti niti prevelik niti premalen. Ako je stopa učenja prevelika, algoritam će premašiti cilj, odnosno minimum, u slučaju da je stopa učenja premala sam proces učenja će trajati predugo (Kramberger i suradnici, 2019). Razlikuju se tri varijante gradijentnog spusta, ovisno o količini podataka koja se koristila za izračun gradijenta ciljne funkcije, a to su: grupni gradijentni spust (engl. *Batch gradient descent*), stohastički gradijentni spust (engl. *Stohastic gradient descent*), gradijenti spust mini skupa (engl. *Mini batch gradient descent*) (Ruder, 2016).

Grupni gradijentni spust izračunava gradijent funkcije greške na cijelom skupu podataka za učenje, odnosno na svim slučajevima, a nakon čega se ažuriraju težine (Ruder, 2016). Kod stohastičkog gradijentnog spusta težine se ažuriraju nakon svakog uzorka,odnosno ovom metodom računaju se gradijenti za svaki slučaj u uzorku za treniranje dok se kod gradijentnog spusta mini skupa ažuriranje težina vrši za svaki mini skup iz skupa podataka (Kramberger i suradnici, 2019)

Prethodno opisana arhitektura neuronske mreže smatra se plitkom (engl. *shallow)* neuronskom mrežom. Novi smjer u istraživanjima u području umjetnih neuronskih mreža donijele su duboke neuronske mreže koje će biti opisane u nastavku.

3.3.2. Duboko učenje i duboke neuronske mreže

Prvu pravu revoluciju u istraživanjima umjetnih neuronskih mreža donijelo je učenje u skrivenom sloju. Umjetne neuronske mreže mogu imati jedan i/ili više skrivenih slojeva koji ujedno predstavljaju i „dubinu“ mreže. Razvojem novih algoritama učenja, veće procesorske moći računala te generiranjem značajnog broja podataka dolazi do razvoja dubokih neuronskih mreža. Danas duboko učenje pokazuje izuzetne performanse u usporedbi s tradicionalnim pristupima strojnom učenju na područjima obrade slika, računalnog vida, prepoznavanja govora, strojnog prevođenja, umjetnosti, obrade medicinskih podataka, robotike i upravljanja, bioinformatike, obrade prirodnog jezika, internetske (engl. *cyber*) sigurnosti i u još mnogim područjima (Alom i suradnici, 2019).

Duboko učenje označava sposobnost učenja kroz više slojeva obrade, dok se „dubina“ u kontekstu umjetnih neuronskih mreža odnosi na broj skrivenih slojeva u neuronskoj mreži (Kavlakoglu, 2020) i upravo je broj skrivenih slojeva temeljna razlika između dubokih i plitkih neuronskih mreža. Prema LeCun i suradnicima (2015) duboko učenje definira se kao računski model koji se sastoji od više slojeva obrade koji su u stanju naučiti složene prikaze podataka i prikladni su za rješavanje visokodimenzionalnih problema. Povećavanje broja skrivenih slojeva u neuronskim mrežama omogućuje višestruke nelinearne transformacije, odabir značajki i druge procese (Zekić-Sušac i suradnici, 2021). Neuronska mreža koja se sastoji od više od tri sloja, koji bi uključivali ulaze i izlaze, može se smatrati algoritmom dubokog učenja (Kavlakoglu, 2020). Ilustrativni primjer plitke i duboke neuronske mreže prikazan je na slici 18.

Slika 18 Plitke vs duboke neuronske mreže

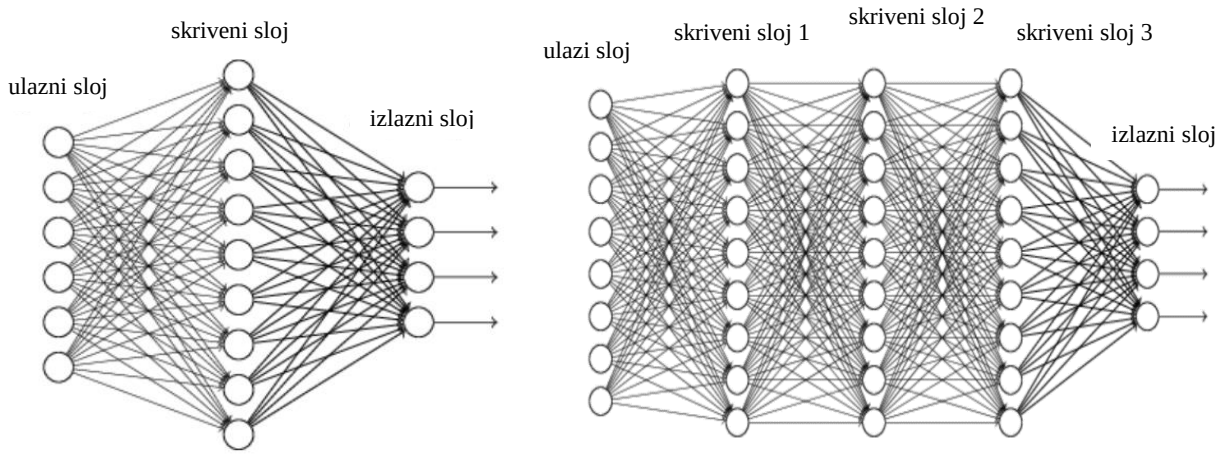

Izvor: Nielsen, M.A, (2015). Neural networks and deep learning (Vol. 25). San Francisco, CA, USA: Determination press.

Učenje u više skrivenih slojeva u ranijim fazama razvoja neuronskih mreža nije bilo učinkovito zbog nekoliko razloga. Problem s dubokim učenjem, odnosno učenjem u više slojeva bio je u algoritmima učenja koji su bolje odgovarali plitkim neuronskim mrežama nego dubokom učenju (Aggarwal, 2018; Glorot i Bengio, 2010). Ujedno, još jedan od razloga za ranije neuspješno učenje neuronskih mreža u više skrivenih slojeva bio je i problem koji je karakterističan za umjetne neuronske mreže, a to su gradijenti (Nielsen, 2015). Duboke neuronske mreže suočavaju se s problemom nestajućih gradijenata (engl. *vanishing gradient problem*), ali i problemom eksplodirajućih gradijenta (engl. *exploding gradient problem)* (Nielsen, 2015). Problem nestajućih gradijenata predstavlja stanje kada se gradijent smanjuje kako se kreće unatrag kroz skrivene slojeve što znači da neuroni u ranijim slojevima uče puno sporije od neurona u kasnijim slojevima (Nielsen, 2015). Suprotno od toga je problem s eksplodirajućim gradijentima. Ako je početna težina gradijenta veća od 1 i mreža ima velik broj slojeva, konačni gradijent može imati vrlo veliku težinu, a to može rezultirati divergencijom i utjecati na preciznost modela i sposobnost treniranja (Liu i suradnici, 2021).

Kako efikasno učiti neuronsku mrežu u više skrivenih slojeva zaintrigiralo je brojne istraživače u području neuronskih mreža što je dovelo do razvoja novih algoritama za učenje, ali i nove „revolucije“ u razvoju neuronskih mreža i ere tzv. dubokog učenja. Bilo koja arhitektura neuronskih mreža može „postati“ duboka. Kao najčešće korištene arhitekture u kontekstu dubokog učenja ističu se konvolucijske neuronske mreže (engl. *Convolutional neural networks - CNNs*), rekurentne neuronske mreže (engl. *Recurrent neural networks - RNNs),* zatvorene

ponavljajuće jedinice (engl. *Long short-term memory/gated recurrent unit (GRU)*), samoorganizirajuće mape (engl. *Self-organizing map (SOM)*), autoenkoderi (engl. *Autoencoders (AE)*), ograničeni Boltzmannov stroj (engl. *Restricted Boltzman machine (RBM)*), mreža dubokih uvjerenja (engl. *Deep belief networks (DBN*)) i mreža dubokog slaganja (engl. *Deep stacking networks (DSNs)*) (Shrestha i Mahmood, 2019).

U nastavku će se prikazati višeslojna perceptron mreža u okvirima dubokog učenja koja je pojašnjena u prethodnom potpoglavlju. Ilustrativni prikaz višeslojne perceptron mreže koju je predložio Werbos 1974., a poboljšali je Rumelhart i suradnici (1986) modificirane s više skrivenih slojeva (Zekić-Sušac i suradnici, 2021) čime ulazi u kontekst dubokog učenja prikazan je u nastavku (slika 19).

Slika 19 Višeslojna neuronska mreže – duboko učenje

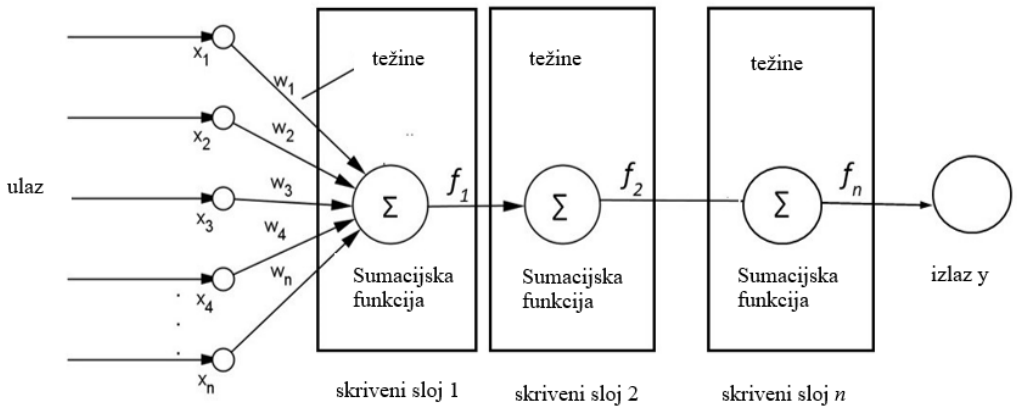

Izvor: Zekić-Sušac, M., Has, A., & Knežević, M. (2021). Predicting energy cost of public buildings by artificial neural networks, CART, and random forest. *Neurocomputing*, *439*, 223-233.

U slučaju dva skrivena sloja, izračunavanje MLP DNN-a može se izraziti (Zekić-Sušac i suradnici, 2021):

$$y_c = f_2\left(\sum_{j=1}^{m} f_1\left(\sum_{i=1}^{n} w_i^{(1)} x_i\right) w_j^{(2)}\right) \tag{12}$$

gdje y_c predstavlja izračunati izlaz, x_i elementi su ulaznog vektora, w_i su težine vektora prvog skrivenog sloja, w_j su težine vektora drugog skrivenog sloja, f_1 je aktivacijska funkcija (*sigmoidna, tangens-hiperbolična, ReLu funkcija ili druga nelinearna funkcija*) korištena prvom skrivenom sloju dok f_2 predstavlja aktivacijsku funkciju koja se koristi u drugom skrivenom sloju. Početni se ponderi nasumično postavljaju iz intervala [-1,1] te se kasnije

prilagođavaju na temelju dobivene greške (Zekić-Sušac i suradnici, 2021). Optimizacijskim algoritmima računaju se gradijenti i pokušava se minimizirati funkcija gubitka (Zaheer i Shaziya, 2019). S obzirom na to da su optimizacijski algoritmi spomenuti i u prethodnom potpoglavlju vezano uz višeslojne neuronske mreže (MLP) u nastavku pojasnit će se algoritam Adam (engl. *Adaptive Moment Estimation*) koji se izdvaja kao jedan od najboljih optimizatora dubokih neuronskih mreža u kontekstu učinkovitijeg i bržeg treniranja neuronske mreže. Adam algoritam računa vlastitu stopu učenja, ali eksponencijalno zaglađuje gradijent prvog reda kako bi ukomponirao momentum u ažuriranje (Aggarwal, 2018). Algoritam Adam izračunava individualne prilagodljive stope učenja za različite parametre iz procjena prvog i drugog momentuma gradijenata, za razliku od stohastičkog gradijentnog spusta koji održava jedinstvenu brzinu učenja za sva ažuriranja težina, a stopa učenja ne mijenja se tijekom treninga (Brownlee, 2018). U Adam algoritmu ažuriranje težina vrši se prema uprosječenom gradijentu, a ne izračunatom (Čupić, 2019). Postoji nekoliko modifikacija Adam algoritma kao što su algoritmi: Adamax, Nadam te AMSGrad (Čupić, 2019).

Metrike za mjerenje uspješnosti jednake su kao i u plitkim neuronskim mrežama. Neovisno o arhitekturi neuronske mreže proces izgradnje modela neuronskih mreža nije jednostavan i uključuje brojne parametre i hiperparametre. U nastavku će biti prikazani koraci u izgradnji modela neuronske mreže koji su se slijedili u izradi ove doktorske disertacije.

3.3.3. Koraci u izgradnja modela neuronske mreže

Neovisno o arhitekturi neuronske ili dubini neuronske mreže postoji nekoliko ključnih elemenata koji se moraju slijediti u procesu izrade modela neuronske mreže. U gotovo svakoj pojedinoj fazi rada neuronske mreže potrebno je odabrati određene parametre, počevši od tipa problema kojima se bavi (predviđanje, klasifikacija), arhitekturu neuronske mreže, dubinu neuronske mreže, podjelu uzorka, funkciju gubitka, pravila i algoritme učenja, epohe, metrike za ocjenu uspješnosti i još brojne druge parametre. Svaki od navedenih parametra može značajno utjecati na konačnu performansu modela neuronske mreže, ali odabir određenih parametra ovisi i o tipu problema koji se modelira. Standardni koraci u izgradnji neuronske mreže prikazani su na slici 20.

Slika 20 Koraci u izgradnji modela neuronske mreže

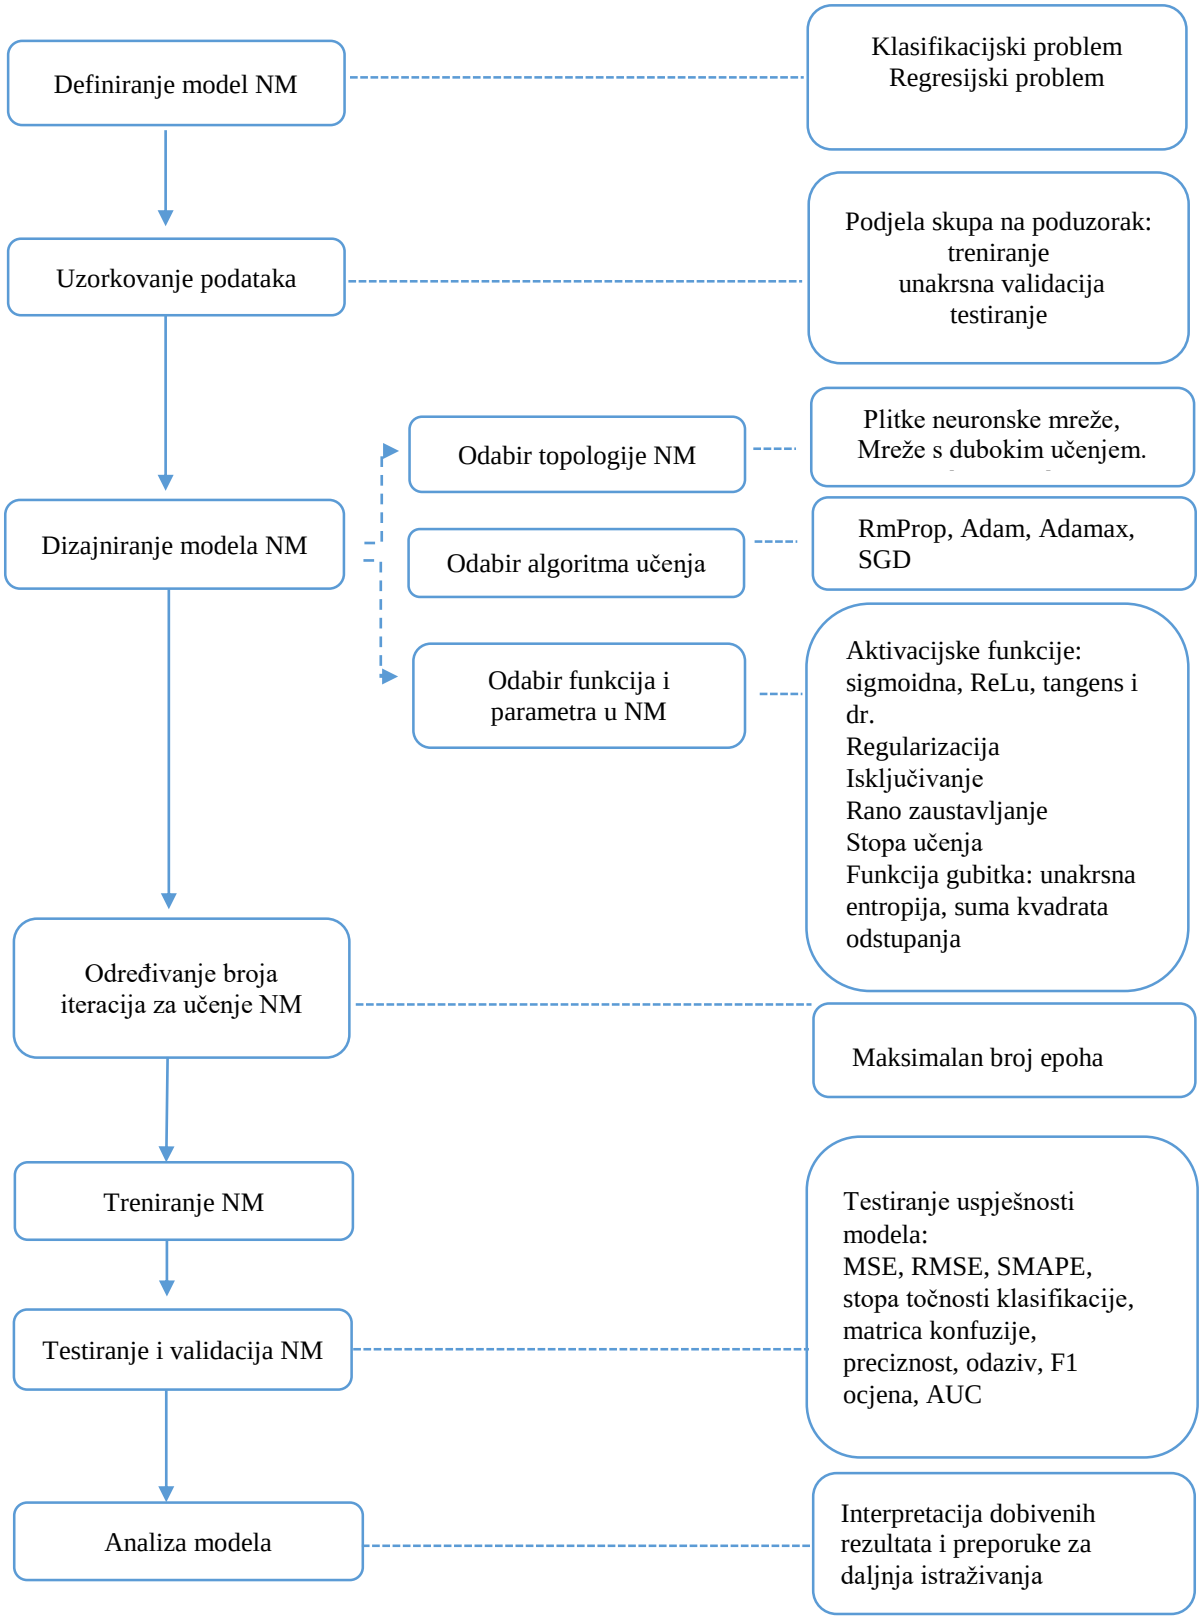

Izvor: Izrada autora

Prvi korak, definiranje modela, pojašnjen je u uvodnom dijelu ovog potpoglavlja. S obzirom na to da neuronske mreže imaju tri faze rada: fazu treniranja te faze unakrsne validacije i testiranja u drugom koraku potrebno je podijeliti ukupan uzorak na tri dijela, odnosno na uzorak za treniranje, unakrsnu validaciju i testiranje. Faza treniranja neuronske mreže zahtjeva najveći broj slučajeva jer o tome ovisi i uspješnost učenja neuronske mreže. Međutim, nema jasnog konsenzusa o točnom postotku slučajeva koji moraju biti u uzorku za treniranje tako da sam postotak slučajeva ovisi o veličini uzorka i istraživaču.

Nakon podjele uzorka pristupa se dizajniranju mreže. Odabire se vrsta neuronske mreže koja može biti višeslojna percepton mreža, konvolucijska neuronska mreža i sl., broj slojeva: plitka ili duboka neuronska mreža te broj neurona u skrivenom sloju. O slojevima i broju neurona može se odlučiti proizvoljno, ali i korištenjem nekih od metoda optimizacije broja skrivenih neurona. U ovom koraku ujedno se izabiru funkcije i hiperparametri kao što je pravilo učenja, prijenosna funkcija, koeficijent učenja i momentum, metode regularizacije i sl. Nakon dizajniranja mreže odabire se broj epoha za treniranje mreže. U idućim koracima mreža se trenira, validira te testira. Testiranje mreže radi se na temelju metrika za ocjenu uspješnosti mreže (ovisno o tipu problema: MSE, RMSE, stopa točnosti klasifikacije, preciznost, odaziv, AUC i dr.). Dobivanjem konačne strukture neuronske mreže slijedi analiza dobivenih rezultata modela neuronske mreže.

3.3.4. Pregled empirijskih istraživanja u istraživanom području temeljenih na strojnom učenju

Područje energetske učinkovitosti u sektoru zgradarstva vrlo je široko i može se promatrati s različitih aspekta. U ovom potpoglavlju prikazat će se empirijska istraživanja u čijem je fokusu korištenje metoda strojnog učenja, posebice umjetnih neuronskih mreža, za upravljanje potrošnjom energije u zgradama. Analizirani su znanstveni radovi iz baze Web of Science, Scopus te Google Schoolar. Ključne riječi korištene u pretraživanju znanstvenih baza bile su: *energy efficiency + energy consumption + nonresidential buildings + machine learning + neural networks + deep learning.* Pretraživanjem su obuhvaćeni radovi objavljeni u periodu od 2005. do 2021. godine.

Općenito, empirijska istraživanja o energetskoj učinkovitosti mogu se svrstati u nekoliko skupina (Foucquier i suradnici, 2013):

- prvi pristup „bijela kutija“ (engl. *white box*) odnosi se na čiste fizičke model kojima se simulira toplinsko ponašanje zgrade,
- drugi pristup „crna kutija“ (engl. *black box*) odnosi se na modele temeljene na strojnom učenju pomoću kojih se predviđa potrošnja energenata (potrošnja struje, plina) unutarnje temperature i sl.,
- treći pristup „siva kutija“ (engl. *gray box*) pristup u izradi modela za predviđanje energetske učinkovitosti koji uključuje kombinaciju fizičkih modela te statističkih modela i strojnog učenja.

Prilikom pregleda relevantne literature u istraživanom području usmjerilo se na drugi pristup s posebnim naglaskom na umjetne neuronske mreže.

Kalogirou (2009) predlaže model neuronske mreže za predviđanje energije potrebne za grijanje zgrade. Ulazni prostor njegovog modela čine građevinske karakteristike zgrade (prozori, podovi, zidovi) te potrebna unutarnja temperatura. Autor navodi da su stope točnosti dobivenog modela zadovoljavajuće te kao prednost umjetnih neuronskih mreža u odnosu na tradicionalne statističke metode ističe brzinu obrade, jednostavnost i sposobnost modela neuronskih mreža da uči na primjerima i poboljšava svoju izvedbu. Autor zaključuje da se kod modeliranja energetske učinkovitosti u zgradarstvu pojavljuje i veliki broj mogućih varijabli, često i šumovi u podacima te kako bi se izgradio model i predvidjela potrošnja energije, kao dobar izbor nameću se nelinearni modeli kao što su neuronske mreže.

Ekici i Aksoy (2009) predložili su model neuronske mreže za predviđanje energije potrebne za grijanje. Ulazni prostor uključivao je 3 varijable: mjeru prozirnosti zgrade (%), orijentaciju zgrade te debljinu izolacije (cm). Dobivena točnost neuronske mreže je vrlo visoka od 94 % do 98 %, odnosno model je generirao vrlo nisku MSE grešku.

Neuronsku mrežu povratnog širenja, neuronsku mrežu radijalne osnovne funkcije (RBFNN), neuronsku mreža opće regresije (GRNN) te metodu potpornih vektora u predviđanju energije potrebne za hlađenje na satnoj razini za poslovne zgrade koristili su Li i suradnici, (2009). Autori su točnost modela ocijenili na temelju generirane RMSE greške i srednje relativne greške (MRE). Autori navode da su sva četiri modela učinkovita u predviđanju potrebne količine energije za hlađenje, ali metoda potpornih vektora i neuronska mreža opće regresije postižu višu stopu točnosti i generalizacije, RMSE greška metode potpornih vektora kretala se oko 1.

Wong i suradnici (2010) predložili su model neuronske mreže za predviđanje potrebne količine energije za grijanje, hlađenje, rasvjetu te ukupnu količinu energije koju generiraju komercijalne zgrade. Ulazni prostor modela neuronske mreže čini devet varijabli od čega su četiri varijable vezane uz meteorološke podatke (prosječna dnevna temperatura, prosječna dnevna temperatura u kišnim danima, količina zračenja, količina vlage) te četiri varijable koje su vezane uz konstrukcijske podatke i podatak o danu u tjednu. Izlaz iz modela bila je količina energije potrebna za grijanje, hlađenje, rasvjetu te ukupna količina potrebne energije. Svi modeli ostvarili su vrlo visoke stope točnosti, preko 94 %.

Ferlito i suradnici (2015) predložili su model umjetne neuronske mreže za predviđanje potrošnje električne energije u vremenskom razdoblju od 3, 6 i 12 mjeseci. Greška dobivenih modela kreće se u rasponu od 15,7 % do 17,97 % i neznatno varira prema horizontu predviđanja (3 mjeseca, 6 mjeseci i 12 mjeseci). Ekstremno duboke mreže koje kombiniraju zbijene autoenkodere (engl. *Sparse Autoencoder (SAE)*) s ekstremnim strojem za učenje (engl. *Extreme learning machine (ELM)*) za kratkoročno predviđanje potrošnje energije (polusatno i satno predviđanje) koristili su Li i suradnici (2017). Zbijeni autoenkoderi koristili su se s ciljem izdvajanja značajki zgrada vezanih uz potrošnju energije dok se ekstremni stroj za učenje (ELM) koristio za predviđanje potrošnje energije. Ovaj pristup modeliranju potrošnje energije i dobivene rezultate autori su usporedili i s drugim metodama strojnog učenja: mrežom širenje unatrag, metodom potpornih vektora, neuronskom mrežom s postupkom poopćene regresije (engl. *Generalized Regression Neural Network*) i višestrukom linearnom regresijom. Dobiveni rezultati ukazuju da predložena metoda ima najbolje rezultate predviđanja potrošnje energije u zgradama (RMSE greška u predviđanju za 60 minuta iznosila je 59,18 %) dok je najlošije rezultate ostvarila metoda višestruke linearne regresija čija je greška predviđanja bila 89,95 %.

Hwang i suradnici (2020) predložili su model za predviđanje mjesečne i dnevne potrošnje električne energije u komercijalnim zgradama. Autori ističu važnost odabira onih značajki, odnosno varijabli koje imaju utjecaj na potrošnju električne energije jer neprikladan odabir ulaznih varijabli može dovesti do smanjene točnosti u predviđanju potrošnje električne energije. Zgrade su podijeljene u 3 skupine, na temelju napravljene hijerarhijske klaster analize i na njima rađeni su modeli za predviđanje potrošnje. Autori izrađuju nekoliko modela za predviđanje potrošnje električne energije u komercijalnim zgradama; sa svim originalnim varijablama u ulaznom prostoru, model koji uključuje samo varijable dobivene nakon korelacijske analize, te model s varijablama dobivenim putem analize osjetljivosti. Modeli za

predviđanje potrošnje električne energije temeljeni su na: neuronskim mrežama, neuronskim mrežama s dubokim učenjem, metodom autoregresivnog intervalnog pomičnog prosjeka s vanjskim varijablama (engl. *Seasonal Auto-Regressive Integrated Moving Average with eXogenous factors (SARIMAX)*), metodi potpornih vektora (engl. *Support vector machine*) te ćelije s dugoročnom memorijom (engl. *Long short-term memory (LSTM)*). Modeli temeljeni na reduciranim varijablama dali su bolje rezultate u odnosu na modele sa svim uključenim varijablama, dok je LSTM metoda dala najmanju grešku u predviđanju potrošnje energije.

Proces predviđanja potrošnje energije u zgradama složen je zbog brojnih čimbenika koji utječu na potrošnju, poput vremenskih uvjeta, performansi, ali i postavki sustava grijanja i hlađenja, namjeni te korisnika zgrade (Mocanu i suradnici, 2014). Prilikom modeliranja potrošnje energije u zgradama nerijetko se pojavljuje velik broj atributa u ulaznom prostoru. U literaturi najčešće se u ulaznom prostoru u različitim modelima strojnog učenja pojavljuju građevinski i konstrukcijski podaci (ukupna površina (m^2) zgrade, broj katova, q-vrijednost, tip objekta), meteorološki podaci (temperatura, količina oborina (mm), brzina vjetra, atmosferski tlak, relativna vlažnost (%)), podaci o načinu korištenja zgrade (broj radnih dana u tjednu, broj radnih sati u tjednu) te podaci o prethodnoj potrošnji (Hwang i suradnici, 2020; Zekić-Sušac, 2017; Ferlito i suradnici, 2015; Al-Mofleh i suradnici, 2009).

Projekt i konstrukcija objekta (oblik zgrade, izolacija i ostali konstrukcijski podaci), upravljanje i održavanje (popravci, zamjena potrošnih dijelova, održavanje objekta) te način korištenja objekta (oprema koja je ugrađena i način na koji djelatnici koriste istu), temperatura, relativna vlažnost zraka te količina oborina izdvajaju se kao najvažniji faktori koji utječu na razinu energetske učinkovitosti nekog objekta (Hwang i suradnici, 2020; Al-Mofleh i suradnici 2009).

U predstavljenim istraživanjima, fokus je na problemu predviđanja. Predviđa se ukupna potrošnja energije, potrošnja pojedinog energenta (električna energija, plin) u dugom i kratkom vremenskom periodu. Ovisno o paradigmi učenja, u istraživanom području, najčešće su korištene metode iz skupine nadziranog učenja: umjetne neuronske mreže, slučajna šuma, metoda potpornih vektora i Gaussovi regresijski modeli distribucije, dok se klasteriranje ističe kao najčešće korištena metoda iz skupine nenadgledanog učenja (Shapi i suradnici, 2021; Runge i Zmeureanu, 2019; Seyedzadeh i suradnici, 2018; Zekić-Sušac, 2017). Usporedbu konvencionalnih metoda, kao što vremenske serije, regresija i metoda temeljenih na strojnom učenju, za predviđanje potrošnje električne energije napravili su Daut i suradnici (2017). Autori

zaključuju da konvencionalnim metodama nedostaje fleksibilnosti u postupanju, nelinearni obrasci koji se pojavljuju u podacima uvelike mogu utjecati na ukupne prognoze konvencionalnih modela, odnosno mogu rezultirati niskim performansama tih modela.

Kao mjerilo uspješnosti modela u literaturi autori su najčešće koristili: srednju kvadratnu grešku (MSE), srednju apsolutnu postotnu grešku (MAPE), srednju pogrešku pristranosti (MBE), koeficijent varijance (CV), osnovnu srednju kvadratnu pogrešku (RMSE), srednju kvadratnu postotnu pogrešku (MSPE) te srednju apsolutnu pogrešku (MAE) (Zekić-Sušac, 2021; Hwangi suradnici, 2020; Runge i Zmeureanu, 2019; Seyedzadeh i suradnici, 2018; Zekić-Sušac, 2017).

Pregledom prethodnih istraživanja vidljivo je da su napravljeni značajni napori u istraživanju i predviđanju potrošnje energije u zgradama. Međutim, većina radova usmjerena je na predviđanje potrošnje energije pojedinog energenta u različitim vremenskim periodima.

4. OPIS ISTRAŽIVANJA I REZULTATI ISTRAŽIVANJA

Empirijski dio ove doktorske disertacije temelji se na istraživanju energetske učinkovitosti u zgradama javnog sektora u Republici Hrvatskoj. Istraživanje se odvija u dva smjera: istraživanje odstupanja u potrošnji energije između stvarnih i proračunskih vrijednosti te izradi modela za klasifikaciju zgrada javnog sektora ovisno o potrošnji stvarne godišnje primarne energije temeljenom na umjetnim neuronskim mrežama. U skladu s tim, ovo poglavlje može se podijeliti na dva dijela. U prvom dijelu poglavlja se bavi fenomenom odstupanja u potrošnji energije, u kojem se uspoređuje proračunska vrijednost potrošnje energije za potrebe toplinske energije i stvarne potrošnje energije za potrebe grijanja u zgradama javnog sektora u Hrvatskoj. Drugi dio poglavlja bavi se izgradnjom modela za klasifikaciju zgrada javnog sektora prema stvarnoj godišnjoj potrošenoj energiji te analizi značajnosti pojedinih ulaznih varijabli i njihovog utjecaja na potrošnju energije u zgradama javnog sektora. Podaci korišteni u empirijskom istraživanju prikupljeni su iz ISGE baze podataka. Postupak preuzimanja, pripreme i predprocesiranja podataka korištenih u empirijskom istraživanju objašnjen je u *Poglavlju 3.*

4.1. Odstupanje u potrošnji energije u zgradama javnog sektora u Republici Hrvatskoj

Odstupanje u potrošnji energije u literaturi poznato je pod nazivom „*performance gap*“, fenomen je koji se javlja ako postoji odstupanje između proračunske i stvarne potrošnje energije koje generiraju zgrade. Odstupanje se može promatrati u oba smjera. Stvarna potrošnja energije može biti značajno viša, ali i niža od proračunske potrošnje energije. U pozadini naizgled jednostavnog tumačenja tog fenomena nema jedinstvenog konsenzusa o samoj veličini odstupanja.

Iz prethodnih poglavlja može se uočiti da se različito tumačenje i mjerenje odstupanja zasigurno nameće kao jedan od uzroka; odstupanje u potrošnji energije može se računati za ukupnu potrošnju energije zgrade, ali i za jedan dio potrošene energije za krajnju upotrebu npr. energija potrošena za zagrijavanje i/ili hlađenje prostora, energija potrošna za rasvjetu, zagrijavanje tople vode i sl. To otežava usporedivost podataka i utvrđivanje magnitude odstupanja. Nadalje, ne postoji jasna granica koliko odstupanje mora postojati kako bi se moglo potvrditi ili odbaciti postojanje tog fenomena. Međutim, jedinstveni konsenzus postignut je oko činjenice da je odstupanje stvarno i kao takvo predstavlja prostor koji može služiti kao putokaz u poboljšanju postojećih modela za predviđanje potrošnje energije kako u fazi

izgradnje zgrade tako i u postupku energetskog certificiranja ali i identificiranja glavnih potrošača energije u zgradama (Shi i suradnici, 2019; International Partnership for Energy Efficiency Cooperation - IPEEC, 2019; Van Dronkelaar i suradnici, 2016).

U Hrvatskoj nisu do sada provedena istraživanja kojima bi se utvrdilo postoji li odstupanje između proračunske i stvarne potrošnje toplinske energije u zgradama javnog sektora. Kao jedan od mogućih razloga nameće se nedostatak, ali i neusklađenost podataka u bazama podataka u kojima se prikupljaju podaci o energetskoj učinkovitosti zgrada te ograničen pristup istima. Kao što je u prethodnim poglavljima navedeno podaci o energetskoj učinkovitosti zgrada javnog sektora u Republici Hrvatskoj mogu se pronaći u tri baze podataka: *ISGE bazi*, *SMIV bazi* te *bazi energetskih certifikata*, međutim, navedene baze nisu međusobno povezane. U ovom istraživanju korišteni su podaci o stvarnoj i proračunskoj potrošnji energije koji su dostupni u ISGE bazi podataka. S obzirom na to da najveći udio potrošene energije u kontekstu krajnje upotrebe energije odlazi za potrebe toplinske energije u ovoj doktorskoj disertaciji usporedit će se stvarna i proračunska potrošnja toplinske energije koja se koristi za potrebe grijanja nestambenih prostora.

4.1.1. Priprema uzorka i ciljne varijable

Proces preuzimanja i pripreme podataka opisan je u *Poglavlju 3, potpoglavlje 3.2. Podaci.* Nakon predprocesiranja, ukupan uzorak zgrada javnog sektora preuzet iz ISGE baze sadrži podatke o 2192 zgrada javnog sektora te 69 varijabli kojima su opisane. Kako bi se usporedila stvarna potrošnja energije u zgradama s proračunskom potrošnjom energije iskazanom na energetskom certifikatu zgrade bilo je potrebno identificirati navedene varijable u ukupnom uzorku. Varijabla koja predstavlja proračunsku potrošnju toplinske energije varijabla je pod nazivom *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ *[kWh/a]*, dok varijabla *Stvarna prosječna trogodišnja potrošnja energije* izražena u kWh predstavlja prosječnu trogodišnju stvarno potrošenu energiju zgrade za razdoblje od 2017. do 2019. godine.

Nakon identifikacije navedenih varijabli izdvojene su samo one zgrade javnog sektora za koje su poznate vrijednosti za obje navedene varijable. Poduzorak za istraživanje odstupanja u potrošnji energije pripremljen je na sljedeći način. U uzorku od 2192 zgrade javnog sektora identificirane su one zgrade koje zadovoljavaju dva uvjeta: da imaju dostupan podatak o *Godišnjoj potrebnoj toplinskoj energiji za grijanje* $Q_{H,nd,ref}$ [*kWh/a*] te podatak o *Stvarnoj*

prosječnoj trogodišnjoj potrošnji energije [kWh]. Na slici 21 prikazan je proces pripreme poduzorka za istraživanje odstupanja u potrošnji energije.

Slika 21 Poduzorak za utvrđivanje odstupanja u potrošnji toplinske energije

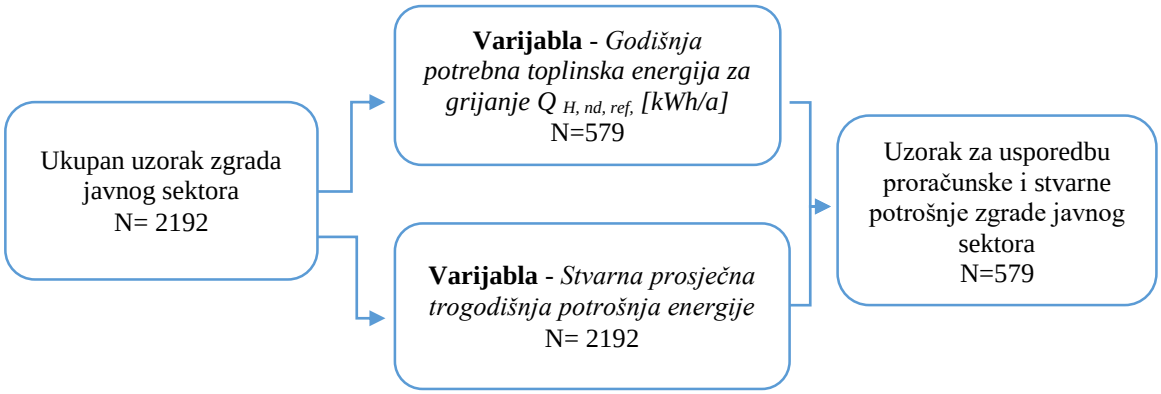

Izvor: Izrada autora

Nadalje, prije usporedbe proračunskih i stvarnih vrijednosti potrošnje energije bilo je potrebno umanjiti vrijednosti varijable koja predstavlja stvarnu potrošnju energije. Razlog za umanjivanje stvarne potrošnje energije je sljedeći: podaci o stvarnoj potrošnji energije koji se nalaze u ISGE sustavu govore o ukupnoj potrošnji energije zgrade pri čemu se ne navodi podatak o pojedinačnim udjelima potrošene energije za potrebe grijanja i/ili hlađenja, zagrijavanje tople vode, rasvjetu i sl. te kako bi se mogla napraviti usporedba s *Proračunskom vrijednosti potrebne toplinske energije za grijanje* iz varijable *Stvarna prosječna trogodišnja potrošnja energije* izuzeo se određeni pretpostavljeni postotak energije koji odlazi za ostale potrebe mimo toplinske energije.

Jedinstven podatak za Republiku Hrvatsku nije poznat, odnosno podatak o potrošnji toplinske energije prema namjeni pojedine zgrade. Podatak o udjelu toplinske energije u finalnoj potrošnji u nestambenim zgradama preuzet je iz *Programa energetske obnove zgrada javnog sektora za razdoblje 2016. – 2020.* prema kojem *je „udio toplinske energije za zgrade izgrađene u periodu izgradnje do 2005. u prosjeku 80 % za kontinentalnu Hrvatsku, te 51 % za primorsku Hrvatsku.* Prema namjeni zgrade, udio toplinske energije u finalnoj potrošnji je *„85 % za obrazovne, 84 % za zgrade za stanovanje te 78 % za bolnice u kontinentalnoj Hrvatskoj*“ (Vlada Republike Hrvatske, 2017). Podatak o potrošnji toplinske energije prema namjeni zgrada za primorsku Hrvatsku nije poznat. Za potrebe istraživanja promotrio se i udio toplinske energije u finalnoj potrošnji nestambenih zgrada u zemljama EU sličnog građevnog

fonda i klimatskih karakteristika. Kao što je navedeno u prethodnom poglavlju, primjerice u Francuskoj, udio toplinske energije iznosi 85 % u ukupno potrošenoj energiji u nestambenim zgradama.

Radi lakše usporedivosti, obje varijable (stvarna i proračunska potrošnja) podijeljene su s varijablom pod nazivom *Ukupna ploština neto podne površine grijanog dijela zgrade* kako bi se dobile dvije nove varijable *Godišnja potrebna toplinska energija za grijanje* $Q_{H, nd, ref}$ *po kWh/m*^{2} te varijabla *Stvarna prosječna trogodišnja potrošnja energije po kWh/m*^{2}. Drugim riječima, potrošnja energije kako stvarne tako i proračunske svedena je na potrošnju po kWh/m^2. Deskriptivna statistika za sve četiri varijable prikazana je u tablici 18.

Tablica 18 Deskriptivna statistika stvarne i proračunske potrošnje toplinske energije

Varijabla	N	Min	1st Qu.	Median	Prosjek	3rd Qu.	Max
Godišnja potrebna toplinska energija za grijanje $Q_{H, nd, ref}$ (kWh/a)	579	3002	53750	128484	233865	280452	4650534
Stvarna prosječna trogodišnja potrošnja toplinske energije za potrebe grijanja (kWh/a)	579	3237	77575	176005	308060	334.168	7428410
Godišnja potrebna toplinska energija za grijanje $Q_{H, nd, ref}$ (kWh/m^2)	579	1,06	62,72	108,32	125,21	161,65	2111,45
Stvarna prosječna trogodišnja potrošnja toplinske energije za potrebe grijanja (kWh/m^2)	579	25,10	88,09	124,04	144,24	175,16	2032,60

Izvor: Izrada autora

Na uzorku od 579 zgrada javnog sektora vidljivo je da je najniža vrijednost za proračunsku potrošnju (varijabla *Godišnja potrebna toplinska energija za grijanje* $Q_{H, nd, ref}$) iznosila 3002 kWh/a, odnosno 1,06 kWh/m^2, dok je najveća proračunska potrošnja iznosila 4650534 kWh/a, odnosno 2111,45 kWh/m^2. Kada se promatra stvarna prosječna trogodišnja potrošnja energije vidljivo je da je najmanja potrošnja iznosila 3237 kWh, odnosno 25,10 kWh/m^2, a najviša stvarna prosječna trogodišnja potrošnja energije iznosila je 7428410 kWh/a, odnosno 2032,60 kWh/m^2.

Prosječna vrijednost varijable *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ iznosi 233865 kWh/a, dok varijabla *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ (kWh/m^2) iznosi 125,21 kWh/m^2. Prosječna vrijednost varijabli koje predstavljaju stvarnu potrošnju energije zgrade javnog sektora je 308060 kWh, odnosno 144,24 kWh/m^2.

U uzorku od 579 javnih zgrada za koje je promatrana proračunska i stvarna potrošnja energije, njih 348 su zgrade za obrazovanje, zatim 139 je administrativnih zgrada, 49 zdravstvenih ustanova, 26 zgrada za socijalne namjene, 9 zgrada namijenjenih kulturi, 5 vojnih objekata i 3 zgrade opće namjene. Najveći broj promatranih zgrada, njih 69,60 % nalazi se u kontinentalnoj Hrvatskoj, dok se 30,40 % promatranih zgrada nalazi u primorskoj Hrvatskoj. U promatranom uzorku nalazi se i 12,95 % zgrada koje se smatraju kulturnim dobrom.

U promatranom uzorku prosječna stvarna trogodišnja potrošnja energije veća je od proračunske potrošnje (varijabla *Godišnja potrebna toplinska energija za grijanje Q H, nd, ref*) kod 353 zgrade javnog sektora. Dok je proračunska potrošnja (varijabla *Godišnja potrebna toplinska energija za grijanje Q H,nd,ref*) veća od stvarne potrošnje energije kod 226 zgrada javnog sektora.

S ciljem utvrđivanja postoje li odstupanja u potrošnji energije testirane su slijedeće hipoteze:

H0: Ne postoji značajna razlika u odstupanju stvarne potrošnje energije i procijenjene potrošnje prema energetskim certifikatima zgrada javnog sektora.

H1: Postoji značajna razlika između stvarne potrošnje energije i procijenjene potrošnje prema energetskim certifikatima zgrada javnog sektora

Kako bi se provjerilo je li očekivana stvarna potrošnja u zgradama javnog sektora veća od proračunske potrošnje, napravljen je jednostrani t-test za testiranje jednakosti očekivanja dvaju zavisnih uzoraka o stvarnoj i proračunskoj potrošnji, uz alternativnu hipotezu da je razlika među očekivanjima veća od nule u korist stvarne potrošnje. Pritom je korištena razina značajnosti α=0,05. Dobivena p vrijednost iznosi 5,934 $*10^{-6}$ što znači da se na razini značajnosti 0,05 odbacuje H0.

U nastavku će detaljnije biti prikazani rezultati odstupanja u potrošnji energije između proračunske vrijednosti prikazane na energetskom certifikatu i stvarne potrošnje energije za potrebe grijanja u zgradama javnog sektora.

4.1.2. Odstupanje u potrošnji energije u zgradama javnog sektora

U promatranom uzorku 60 % zgrada (353 zgrade od 579 zgrada) stvarno troši više energije za potrebe grijanja nego što su njihove proračunske vrijednosti. Deskriptivna statistika i vrijednosti kako proračunske tako i stvarne potrošnje predstavljene su u tablici 19.

Prosječna stvarna potrošnja energije u identificiranim zgradama javnog sektora iznosila je 162,30 kWh/m² što bi bilo ekvivalentno energetskom razredu E dok je prosjek proračunske potrošnje energije u tom podskupu zgrada javnog sektora iznosio 91,40 kWh/m² što bi bilo ekvivalentno energetskom razredu C. Iz toga može se zaključiti da su proračunska energetska svojstva promatranih zgrada javnog sektora precijenjena.

Tablica 19 Deskriptivna statistika - odstupanje u potrošnji energije

Varijabla	N	Minimum	1. kvartil	Median	Prosjek	3. kvartil	Maksimum
Godišnja potrebna toplinska energija za grijanje $Q_{H, nd, ref}$ po kWh/m^2	353	4,18	50,62	81,41	91,40	124,06	335,37
Stvarna prosječna trogodišnja potrošnja energije po kWh/m^2	353	30,72	100,41	145,00	162,30	203,17	1416,11

Izvor: Izrada autora

Stvarna potrošnja energije za potrebe grijanja odstupa od proračunske potrošnje u različitim rasponima. Raspon odstupanja u potrošnji energije prikazan je u tablici 20. Najveći broj zgrada javnog sektora, njih 58 bilježi odstupanje između stvarne i proračunske potrošnje energije za potrebe grijanja prostora u rasponu od 20 % do 30 %. Međutim, kod 13 zgrada javnog sektora zabilježeno je odstupanje u rasponu od 90 % do 100 % stvarne količine potrošene energije u odnosu na proračunsku vrijednost potrošnje energije.

Tablica 20 Raspon odstupanja u potrošnji energije

Raspon odstupanja (%)	**Broj zgrada javnog sektora**
0-10	35
10-20	47
20-30	59
30-40	42
40-50	48
50-60	38
60-70	30
70-80	20
80-90	22
90-100	13
Ukupno	**353**

Izvor: Izrada autora

Od ukupnog broja zgrada javnog sektora kod kojih je identificirana veća stvarna potrošnja toplinske energije u odnosu na proračunsku vrijednost potrošnje kod 90 % zgrada javnog sektora identificirano je odstupanje u potrošnji energije veće od 10 %.

Kako bi se prikazalo pojedinačno odstupanje u potrošnji energije u tablici 21 su prikazani podaci za 21 zgradu javnog sektora ovisno o prethodno prikazanim veličinama odstupanja u potrošnji energije.

Tablica 21 Pojedinačno odstupanje u potrošnji energije

Zgrada	**Stvarna potrošnja energije – (kWh/m^2)**	**Proračunska potrošnja energije – (kWh/m^2)**	**Razlika (kWh/m^2)**	**Veličina odstupanja (%)**	**Namjena zgrade**
Zgrada 1	138,53	126,55	11,99	8,65	Zgrada za obrazovanje
Zgrada 2	167,70	151,27	16,42	9,79	Zgrada za obrazovanje
Zgrada 3	129,24	112,61	16,62	12,87	Administrativna zgrada
Zgrada 4	51,50	41,27	10,23	19,86	Zgrada za obrazovanje
Zgrada 5	272,46	195,54	76,92	28,23	Zgrada socijalne namjene
Zgrada 6	94,58	67,09	27,49	29,06	Zgrada za obrazovanje

Zgrada 7	160,70	112,91	47,79	29,74	Zdravstvena institucija
Zgrada 8	151,22	99,47	51,74	34,22	Zdravstvena institucija
Zgrada 9	221,27	137,31	83,96	37,95	Administrativna zgrada
Zgrada 10	112,54	68,06	44,48	39,52	Zgrada za obrazovanje
Zgrada 11	311,62	182,15	129,48	41,55	Zdravstvena institucija
Zgrada 12	119,55	65,97	53,58	44,82	Administrativna zgrada
Zgrada 13	175,83	88,77	87,07	49,52	Zgrada za obrazovanje
Zgrada 13	232,15	116,54	115,61	49,80	Zgrada za obrazovanje
Zgrada 14	177,60	68,65	108,94	61,34	Zgrada socijalne namjene
Zgrada 15	209,81	74,58	135,23	64,45	Zdravstvena institucija
Zgrada 16	240,51	75,26	165,25	68,71	Administrativna zgrada
Zgrada 17	77,89	22,05	55,84	71,70	Zgrada za obrazovanje
Zgrada 18	146,35	28,84	117,51	80,29	Administrativna zgrada
Zgrada 19	196,47	31,69	164,78	83,87	Zdravstvena institucija
Zgrada 20	206,34	18,28	188,07	91,14	Zdravstvena institucija
Zgrada 21	266,11	17,46	248,64	93,44	Administrativna zgrada

Izvor: Izrada autora

Iz tablice 21 vidljiv je visok raspon pojedinačnog odstupanja. *Zgrada 1* predstavlja zgradu namijenjenu obrazovanju čija je proračunska potrošnja energije na godišnjoj razini procijenjena na 126,55 kWh/m^2, ali stvarna prosječna trogodišnja potrošnja te zgrade je 8,63 % veća od procijenjene i iznosila je 138,53 kWh/m^2. *Zgrada 17* također je namijenjena obrazovanju te je u ovom slučaju stvarna prosječna trogodišnja potrošnja energije veća za 71,70 % od proračunske vrijednosti potrošnje navedene zgrade. *Zgrada 3* je administrativna zgrada čija je stvarna potrošnja energije veća za 12,87 % od njezine proračunske vrijednosti potrošnje, dok je kod *Zgrade 9 i Zgrade 21* koje su također administrativne namjene zabilježeno odstupanje u potrošnji energije koje je iznosilo za *Zgradu 9* 37,95 %, odnosno za *Zgradu 21*

93,44 %. *Zgrada 2* predstavlja zdravstvenu instituciji kod koje je identificirano odstupanje, odnosno stvarna prosječna trogodišnja potrošnja energije veća za 29,74 % od proračunske vrijednosti potrošnje navedene zgrade. Zgrade namijenjene zdravstvu su i *Zgrada 19* te *Zgrada 20* kod kojih je identificirano značajno odstupanje od proračunske vrijednosti potrošnje od 83,87 % te 91,14 %.

Među zgradama kod kojih je utvrđena veća stvarna potrošnja energije najveći broj zgrada pripada u skupinu zgrada obrazovne namjene, odnosno one čine 52 % uzorka, uredske zgrade 28 %, zdravstvene institucije 10 %, zgrade socijalne namjene 6 % te zgrade kulturne namjene 2 % u promatranom uzorku. S obzirom na heterogenost zgrada prikazat će se prosječna *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ *po kWh/m*^{2} i *Stvarna prosječna trogodišnja potrošnja energije po kWh/m*^{2} te veličina odstupanja u pojedinoj skupini zgrada javnog sektora ovisno o njihovoj namjeni (tablica 22). Iz tablice 22 vidljivo je da se odstupanje kreće u rasponu od 43 % do 48 % za zgrade obrazovne namjene, uredske zgrade, zdravstvene institucije te u zgradama socijalne namjene. Najviše odstupanje zabilježeno je u skupini zgrada kulturne namjene i ono je iznosilo 61,27 %. Međutim, uzrok tome može biti i u uzorku, jer za samo 7 zgrada kulturne namjene utvrđena je veća stvarna potrošnja energije u odnosu na proračunsku potrošnju energije.

Tablica 22 Odstupanje u potrošnji prema namjeni zgrada javnog sektora

Namjena zgrade		**Godišnja potrebna toplinska energija za grijanje Q H,nd,ref po kWh/m^2**	**Stvarna prosječna trogodišnja potrošnja energije po kWh/m^2**	**Odstupanje u potrošnji energije**
	N 353	**Prosjek**	**Prosjek**	
Zgrade obrazovne namjene	185	77,42	136,89	43,45 %
Uredske zgrade	100	101,56	178,14	42,99 %
Zdravstvene institucije	34	131,18	248,25	47,16 %
Zgrade socijalne namjene	22	104,40	199,08	47,56 %
Zgrade kulturne namjene	7	32,57	84,09	61,27 %

Izvor: Izrada autora

Kao što je ranije navedeno, najveći broj zgrada kod kojih je identificirana veća stvarna potrošnja energije od one proračunske potrošnje energije pripada skupni zgrada obrazovne namjene, njih 185. Prosječna *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ *po* kWh/m^2, odnosno prosječna proračunska potrošnja energije u zgradama obrazovne namjene iznosi 77,42 kWh/m^2, dok prosjek *Stvarne potrošnje energije* tih zgrada iznosi 136,89 kWh/m^2. U slučaju zgrada obrazovne namjene stvarna potrošnja energije veća je od one proračunske za 43,45 %. Profil zgrada obrazovne namjene, kod kojih je stvarna potrošnja energije veća od proračunske potrošnje energije je sljedeći:

- smještene su u kontinentalnoj Hrvatskoj,
- izgrađene su prije 1970. godine,
- ne uživaju status kulturnog dobra,
- imaju više od 550 korisnika zgrade,
- imaju do 50 zaposlenika,
- u prosjeku su u upotrebi 9 radnih sati u danu, 361 dan godišnje,
- imaju energetski razred C,
- stvarna potrošnja energije ekvivalentna je energetskom razredu D.

Sljedeće su po brojnosti u uzorku uredske zgrade, njih 100. Prosječna *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ po kWh/m^2, odnosno prosječna proračunska potrošnja energije u uredskim zgradama iznosi 101,56 kWh/m^2, dok prosjek *Stvarne potrošnje energije* tih zgrada iznosi 178,14 kWh/m^2. Stvarna potrošnja energije po m^2 veća je od one proračunske za 42,99 %. Profil uredskih zgrada kod kojih je utvrđena veća stvarna potrošnja energije u odnosu na proračunsku je sljedeći:

- smještene su u kontinentalnoj Hrvatskoj,
- izgrađene su u razdoblju između 1945. i 1970. godine,
- ne uživaju status kulturnog dobra,
- u prosjeku su u upotrebi 8 radnih sati u danu, 260 dana godišnje,
- imaju više od 50 zaposlenih,
- imaju energetski razred C ili D,
- stvarna potrošnja energije ekvivalentna je energetskom razredu E.

Zdravstvene institucije čine 10 % poduzorka kod kojeg je utvrđena viša stvarna potrošnja energije. Prosječna *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ *po* kWh/m^2 u zgradama zdravstvene namjene iznosi 131,18 kWh/m^2, dok prosjek *Stvarne potrošnje energije*

tih zgrada iznosi 248,25 kWh/m^2. Stvarna potrošnja energije po m^2 veća je od proračunske za 47,16 %. Profil zdravstvenih institucija kod kojih je utvrđena veća stvarna potrošnja energije u odnosu na proračunsku je sljedeći:

- smještene su u kontinentalnoj Hrvatskoj,
- izgrađene su prije 1970. godine,
- ne uživaju status kulturnog dobra,
- u prosjeku su u upotrebi 24 radna sata u danu, 365 dana godišnje,
- imaju više od 550 korisnika,
- imaju više od 50 zaposlenih,
- imaju energetski razred E,
- stvarna potrošnja energije ekvivalentna je energetskom razredu F.

Zgrade socijalne namjene čine 6 % uzorka. Prosječna *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ po *kWh/m^2* u zgradama socijalne namjene iznosi 104,40 kWh/m^2 dok prosjek *Stvarne potrošnje energije* tih zgrada iznosi 199,08 kWh/m^2. Stvarna potrošnja energije po m^2 veća je od proračunske za 47,56 %. Profil zgrada socijalne namjene kod kojih je utvrđena veća stvarna potrošnja energije u odnosu na proračunsku je sljedeći:

- smještene su u kontinentalnoj Hrvatskoj,
- izgrađene su u razdoblju od 1981. do 1991. godine,
- ne uživaju status kulturnog dobra,
- u prosjeku su u upotrebi 17 radnih sati u danu, 364 dana godišnje,
- imaju do 150 korisnika,
- imaju više od 50 zaposlenih,
- imaju energetski razred D,
- stvarna potrošnja energije ekvivalentna je energetskom razredu E.

Najmanji udio, odnosno 2 % u promatranom uzorku, zauzimaju zgrade kulturne namjene. Prosječna *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ po *kWh/m^2* u zgradama s kulturnom namjenom iznosi 32,57 kWh/m^2, dok prosjek *Stvarne potrošnje energije* tih zgrada iznosi 84,09 kWh/m^2. Stvarna potrošnja energije po m^2 veća je od proračunske za 61,27 %.

Profil zgrada kulturne namjene kod kojih je utvrđena veća stvarna potrošnja energije u odnosu na proračunsku je sljedeći:

- smještene u primorskoj Hrvatskoj,

- izgrađene u razdoblju od 1946. do 1980. godine,
- ne uživaju status kulturnog dobra,
- u prosjeku su u upotrebi 8 radnih sati u danu, 364 dana godišnje
- do 500 korisnika,
- više od 20 zaposlenih,
- energetskog razreda B,
- stvarna potrošnja energije ekvivalentna je energetskom razredu C.

U ovom potpoglavlju potvrđena je pretpostavka o postojanju odstupanja u potrošnji energije zgrada javnog sektora u Hrvatskoj. Međutim, u nastavku su se istražili i oni slučajevi u kojima je proračunska potrošnja energije veća od stvarne potrošnje energije u zgradama javnog sektora.

4.1.2. Odstupanje u potrošnji energije u zgradama javnog sektora – točnost postojećih modela

U promatranom uzorku 40 % zgrada (226 zgrada od 579 zgrada) stvarno troši manje energije za potrebe grijanja nego što je predviđeno temeljem proračunske vrijednosti. Prosječna stvarna potrošnja energije u identificiranim zgradama javnog sektora iznosila je 162,30 kWh/m² što bi bilo ekvivalentno energetskom razredu E, dok je prosjek proračunske potrošnje energije iznosio 91,40 kWh/m² što bi bilo ekvivalentno energetskom razredu C (tablica 23).

Tablica 23 Odstupanje u potrošnji energije - Proračunska potrošnja energije > Stvarna potrošnja energije

Varijabla	N	Minimum	1. kvartil	Median	Prosjek	3. kvartil	Maksimum
Godišnja potrebna toplinska energija za grijanje Q H,nd,ref po kWh/m^2	226	29,58	113,49	156,75	179,44	210,35	2111,45
Stvarna prosječna trogodišnja potrošnja energije po kWh/m^2	226	25,10	61,29	103,26	116,03	142,58	2023,60

Izvor: Izrada autora

Iz tablice 23 vidljivo je da prosječna stvarna potrošnja energije u zgradama javnog sektora u poduzorku zgrada javnog sektora kod kojih je identificirana niža stvarna potrošnja energije

iznosi 116,03 kWh/m^2 što bi bilo ekvivalentno energetskom razredu D, dok je prosjek proračunske potrošnje energije iznosio 179,44 kWh/m^2 što bi bilo ekvivalentno energetskom razredu E.

Raspon odstupanja u potrošnji energije prikazan je u tablici 24.

Tablica 24 Raspon odstupanja u potrošnji energije – proračunska potrošnja energije > stvarna potrošnja energije

Raspon odstupanja (%)	**Broj zgrada javnog sektora**
0-10	43
10-20	29
20-30	22
30-40	19
40-50	10
50-60	11
60-70	2
70-80	11
80-90	5
90-100	12
> 100	62
Ukupno	226

Izvor: Izrada autora

Od ukupnog broja zgrada javnog sektora kod kojih je identificirana manja količina stvarno potrošene energije u odnosu na proračunsku količinu energije kod 43 zgrade ona je manja od 10 %, dok je kod 62 zgrade javnog sektora identificirano odstupanje veće od 100 %. Udio zgrada u uzorku sličan je kao i u prethodno opisanom slučaju, najveći broj zgrada pripada obrazovnom sektoru (72 %), nakon čega slijede uredske zgrade (16 %), zdravstvene institucije (7 %), zgrade socijalne namjene (2 %), zgrade namijenjene kulturi (1 %) i vojni objekti (1 %).

U tablici 25 prikazana je prosječna *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ po *kWh/m^2* i *Stvarna prosječna trogodišnja potrošnja energije* po *kWh/m^2* te veličina

odstupanja u pojedinoj skupini zgrada javnog sektora kod kojih je utvrđena niža količina stvarno potrošene energije od proračunske količine energije.

Tablica 25 Odstupanje u potrošnji prema namjeni zgrada javnog sektora - proračunska potrošnja energije > stvarna potrošnja energije

Namjena zgrade		**Godišnja potrebna toplinska energija za grijanje Q H,nd,ref po kWh/m^2**	**Stvarna prosječna trogodišnja potrošnja energije po kWh/m^2**	**Odstupanje u potrošnji energije (%)** ↓
	N	**Prosjek**	**Prosjek**	
Zgrade obrazovne namjene	163	164,69	99,89	64,87
Uredske zgrade	37	225,59	179,68	25,55
Zdravstvene institucije	15	247,17	171,78	43,89
Zgrade socijalne namjene	4	52,78	206,37	291,04
Zgrade kulturne namjene	2	202,11	142,27	42,07

Izvor: Izrada autora

Prosječna *Godišnja potrebna toplinska energija za grijanje* $Q_{H,\,nd,\,ref}$ *po kWh/m*^{2}, odnosno prosječna proračunska potrošnja energije u zgradama obrazovne namjene iznosi 164,69 kWh/m^2 te je veća od stvarne prosječne potrošnje za 64,87 %. Profil zgrada obrazovne namjene kod kojih je utvrđena niža količina stvarno potrošene energije je sljedeći:

- smještene su u kontinentalnoj Hrvatskoj,
- izgrađene su između 1946. i 1970. godine,
- ne uživaju status kulturnog dobra,
- imaju više od 550 korisnika zgrade,
- imaju do 50 zaposlenika,
- u prosjeku su u upotrebi 8 radnih sati u danu, 312 dana godišnje,
- imaju energetski razred D,
- stvarna potrošnja energije ekvivalentna je energetskom razredu C.

Kod 38 uredskih zgrada zabilježena je niža prosječna stvarna potrošnja energije za 25,55 % od njezine proračunske vrijednosti potrošnje. Prosječna *Godišnja potrebna toplinska energija za grijanje* $Q_{H,\,nd,\,ref}$ po *kWh/m*^{2}, odnosno prosječna proračunska potrošnja energije u uredskim

zgradama iznosi 225,59 kWh/m^2, dok prosjek *Stvarne potrošnje energije* tih zgrada iznosi 179,68 kWh/m$^{2.}$ Profil uredskih zgrada kod kojih je utvrđena niža stvarna potrošnja energije u odnosu na proračunsku vrijednost potrošnje je sljedeći:

- smještene su u kontinentalnoj Hrvatskoj,
- izgrađene se u razdoblju između 1945. i 1970. godine,
- ne uživaju status kulturnog dobra,
- u prosjeku su u upotrebi 8 radnih sati u danu, 260 dana godišnje,
- imaju više od 50 zaposlenih,
- imaju energetski razred F,
- stvarna potrošnja energije ekvivalentna je energetskom razredu E.

Zdravstvene institucije s udjelom od 7 % treće su po brojnosti u uzorku te je prosječna stvarna potrošnja energije po m^2 niža od proračunske potrošnje energije za 43,89 %. *Prosječna godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ *po kWh/m^2* iznosi 247,17 kWh/m^2, dok prosjek *Stvarne potrošnje energije* tih zgrada iznosi 171,78 kWh/m^2. Profil zdravstvenih institucija kod kojih je utvrđena niža stvarna potrošnja energije u odnosu na proračunsku potrošnju energije je sljedeći:

- smještene su u kontinentalnoj Hrvatskoj,
- izgrađene su nakon 2000. godine,
- ne uživaju status kulturnog dobra,
- u prosjeku su u upotrebi 24 radna sata u danu, 364 dana godišnje,
- imaju manje od 300 korisnika,
- imaju manje od 20 zaposlenih,
- imaju energetski razred F,
- stvarna potrošnja energije ekvivalentna je energetskom razredu E.

Zgrade socijalne namjene čine 2 % uzorka. Stvarna potrošnja energije po m^2 niža je od proračunske za 291,04 %. Prosječna *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ *po kWh/m^2* u zgradama socijalne namjene iznosi 206,37 kWh/m^2, dok prosjek *Stvarne potrošnje energije* tih zgrada iznosi 52,78 kWh/m^2.

Profil zgrada socijalne namjene kod kojih je utvrđena niža stvarna potrošnja energije u odnosu na proračunsku je sljedeći:

- smještene su u primorskoj Hrvatskoj,
- izgrađene su u razdoblju od 1946. do 1970. godine,
- ne uživaju status kulturnog dobra,
- u prosjeku su u upotrebi 18 radnih sati u danu, 364 dana godišnje,
- imaju do 50 korisnika,
- imaju do 20 zaposlenih,
- imaju energetski razred G,
- stvarna potrošnja energije ekvivalentna je energetskom razredu C.

U promatranom uzorku zgrade kulturne namjene čine 1 % uzorka (2 zgrade javnog sektora). Prosječna *Godišnja potrebna toplinska energija za grijanje* $Q_{H,nd,ref}$ po kWh/m^2 u zgradama kulturne namjene iznosi 202,11 kWh/m^2, dok prosjek *Stvarne potrošnje energije* tih zgrada iznosi 142,27 kWh/m^2. Stvarna potrošnja energije po m^2 niža je od proračunske za 42,07 %.

4.2. Izrada modela strojnog učenja za predviđanje potrošnje energije zgrada javnog sektora

Unatoč obvezi energetskog certificiranja zgrada javnog sektora i obvezi unosa podataka u ISGE, u promatranom uzorku od 2192 zgrada javnog sektora proračunska potrošnja energije, odnosno energetski razred poznat je za 26,14 % zgrada javnog sektora. Nekoliko je važnih uzorka tome:

- korisnici/vlasnici zgrada nisu unosili podatke o zgradi javnog sektora u ISGE sustav. Nedostatak edukacije korisnika/vlasnika zgrada i definiranje odgovorne osobe (zaposlenika) unutar zgrade javnog sektora koja će biti zadužena za unos podataka u ISGE sustav jedan je od razloga.
- Ministarstvo prostornog uređenja, graditeljstva i državne imovine koristi dvije baze u koje se prikupljaju podaci o energetskim certifikatima, pri čemu jedna od baza nije strukturirana i podaci u njoj gotovo su neiskoristivi, a druga je online baza podataka pod nazivom *Informacijski sustav energetskih certifikata* koja služi za izdavanje i pohranu energetskih certifikata te koja je uspostavljena 2017. godine.
- nepovezanost triju sustava koja prikupljaju i upravljaju podacima o energetskoj učinkovitosti i potrošnji energije u zgradama: *ISGE sustava, Informacijskog sustava*

energetskih certifikata te *Sustava za praćenje, mjerenje i verifikaciju ušteda energije (SMIV).*

Cjelokupni sustav upravljanja i praćenja potrošnje energije u zgradama dobro je zamišljen, međutim nepovezanost svih navedenih sustava za upravljanje energetskom učinkovitosti te mala angažiranost korisnika/vlasnika zgrada javnog sektora prepreka je koja se mora svladati kako bi se zaista učinkovito upravljalo energetskom učinkovitosti u zgradama javnog sektora te planirala obnova energetski neučinkovitih zgrada.

Nepovezanost sustava za upravljanje potrošnjom energije u zgradama javnog sektora, mali udio energetskih certifikata, nedostatak informacija o stvarno potrošenoj količini energije u zgradama, utvrđena odstupanja stvarno potrošene količine energije te niska stopa točnosti klasifikacije postojećeg proračunskog modela, motiv su za drugi dio provedenog empirijskog istraživanja koji nastoji dati odgovore na sljedeća pitanja:

Kako upravljati procesom povećanja energetske učinkovitosti i energetskom obnovom zgrada javnog sektora ako se ne zna koliko je zgrada „trenutno“ energetski učinkovita?

Može li javni sektor, odnosno tijela zadužena za upravljanje i praćenje energetske učinkovitosti inovativnim korištenjem postojećih sustava za upravljanje potrošnjom energije utvrditi energetsko stanje zgrade i identificirati energetski neučinkovite zgrade?

Kao odgovor na navedena pitanja proizašla je ideja za poboljšanjem postojećeg ISGE sustava dodavanjem nove značajke u sustav koja bi omogućila klasificiranje zgrada javnog sektora prema njihovoj stvarnoj potrošnji energije. Za klasificiranje zgrada javnog sektora prema njihovoj stvarnoj potrošnji energije napravljen je model temeljen na strojnom učenju – umjetnim neuronskim mrežama.

Model za klasificiranje zgrada prema stvarnoj potrošnji energije, osim što omogućuje identifikaciju zgrada s najvećom potrošnjom energije, može dati uvid korisnicima zgrade javnog sektora u stvarne performanse zgrade, ali i biti i poticaj korisnicima zgrada javnog sektora za uključivanje u proces energetske obnove zgrada. Postupak izrade modela strojnog učenja za predviđanje stvarne potrošnje energije u zgradama javnog sektora objašnjen je u nastavku.

4.2.1. Predprocesiranje podataka i definiranje modela strojnog učenja

Predprocesiranje podataka neizostavan je korak strojnog učenja. Proces pripreme podataka i njihova vizualizacija prikazani su u prethodnom poglavlju *Metodologija*, potpoglavlje *Podaci*. S obzirom na važnost faze predprocesiranja u nastavku će se dati kratka sinteza opisanog u prethodnom poglavlju te prikazati proces pripreme ciljne varijable predloženog klasifikacijskog modela strojnog učenja. Podaci su preuzeti iz ISGE sustava, pripremljen je uzorak koji obuhvaća 2192 zgrade javnog sektora i 69 varijabli kojima su iste opisane, a koji je temelj za provedbu empirijskog istraživanja.

Kako bi se izradio model za klasificiranje zgrada javnog sektora prema stvarnoj potrošnji primarne energije bilo je potrebno izdvojiti poduzorak iz ukupnog uzorka koji je pripremljen u prethodnim koracima te definirati izlaznu varijablu modela. Iz poduzorka isključene su 4 varijable koje su bilježile više od 70 % nedostajućih vrijednosti koje su bile nužne za izračun odstupanja u potrošnji energije te varijable vezane uz troškove energije.

Varijabla *Prosječna trogodišnja potrošnja energije kWh/m*^{2} odabrana je za izlaznu, ciljnu varijablu za model klasifikacije zgrada javnog sektora prema stvarnoj potrošnji energije. Međutim, navedena varijabla u svom izvornom obliku izražena je numerički i prikazuje količinu stvarno potrošene energije izraženu u kWh/m^2 i u tom obliku nije prikladna za istraživani tip problema. Ovo istraživanje bavi se klasifikacijskim tipom problema te se varijabla *Prosječna trogodišnja potrošnja energije kWh/m*^{2} transformirala prema unaprijed definiranim kriterijima u novu varijablu nazvanu *Klasa*.

Prilikom definiranja varijable *Klasa* vodilo se uputom Europske komisije (2016) koja navodi da prilikom kreiranja mjera i politika države članice moraju identificirati one zgrade iz svojeg nacionalnog fonda zgrada koje imaju najlošija energetska svojstva bilo određivanjem određenog praga, kao energetski razred, na temelju potrošnje primarne energije (izražene u kWh/m^2) ili usmjeravanjem pozornosti na zgrade izgrađene prije određenog datuma.

Nova varijabla *Klasa* sastoji se od dvije klase: *Klase 0* koja predstavlja zgrade javnog sektora s dobrim energetskim svojstvima te *Klase 1* koja predstavlja zgrade s lošim energetskim svojstvima. Međutim, prvo se definiralo što predstavljaju „dobra“ energetska svojstva zgrade javnog sektora, a što „loša“ svojstva zgrada kako bi se zgrade javnog sektora mogle razvrstati u jednu od navedenih klasa. Transformacija varijable *Prosječna trogodišnja potrošnja energije (kWh/m*^{2}*)* napravljena je kroz nekoliko koraka.

U prvom koraku svaka zgrada javnog sektora svrstala se u pripadajući energetski razred prikazan u tablici 26 *Specifična godišnja primarna energija,* E_{prim} *kWh/m²a* čime je svakoj zgradi dodijeljen energetski razred, ovisno o potrošnji energije, od A+ do G. Nakon što su zgrade svrstane u energetske razrede uslijedio je drugi korak. U drugom koraku, definiralo se koji energetski razredi opisuju dobra energetska svojstva, a koji opisuju lošija energetska svojstva.

Zgrade javnog sektora koje su na temelju stvarne primarne potrošnje u prvom koraku svrstane u energetski razred A+, A ili B neovisno o geografskom području označene su kao zgrade s dobrim energetskim svojstvima i dodijeljena im je *Klasa 0 – energetski učinkovite zgrade*. Zgrade javnog sektora koje su prema svojoj stvarno potrošenoj količini energije svrstane u energetski razred A+, A ili B označene su energetski učinkovitim zgradama jer prema svojoj potrošnji energije zadovoljavaju i trenutno važeće tehničke propise.

Energetski razred C u ovom je istraživanju bio prijelazni razred i bilo je potrebno razlučiti karakterizira li on dobra ili loša energetska svojstva zgrade. Razlog tome leži u geografskoj lokaciji. Energetski razred C ne označava ista energetska svojstva za zgradu smještenu u kontinentalnoj i zgradu smještenu u primorskoj Hrvatskoj. Zbog klimatskih uvjeta zgrade u primorskoj Hrvatskoj troše značajno manje toplinske energije. To je vidljivo i iz *Tehničkog propisa o racionalnoj uporabi energije i toplinskoj zaštiti u zgradama* (NN 128/15, 70/18, 73/18, 86/18, 102/20) u Prilogu B, tablici 1 *Najveće dopuštene vrijednosti koeficijenata prolaska topline, U (W/(m^2 ∗ K)), građevnih dijelova novih zgrada i nakon rekonstrukcije postojećih zgrada* prema kojoj su *U* vrijednosti vanjskih zidova u primorskoj Hrvatskoj za 1/3 veće od onih u kontinentalnoj Hrvatskoj (u primorskoj Hrvatskoj maksimalna je *U* vrijednost 0,45 W/(m^2 ∗ K), dok su u kontinentalnoj Hrvatskoj stroži zahtjevi te je maksimalna *U* vrijednost 0,30 W/(m^2 ∗ K)).

Iz tog razloga zgradama javnog sektora koje su svrstane u energetski razred C prema stvarno potrošenoj količini primarne energije, a smještene su u kontinentalnoj Hrvatskoj, u ovom istraživanju dodijeljena je *Klasa 0 – energetski učinkovite zgrade* i nisu prioritetne u uključivanje u program energetske obnove. Ako je zgrada javnog sektora svrstana u energetski razred C na temelju svoje stvarne primarne potrošnje energije i smještena je u primorskoj Hrvatskoj istoj je dodijeljena *Klasa 1 – energetski neučinkovita zgrada.*

Zgrade javnog sektora koje su svrstane u energetske razrede D, E, F ili G prema svojoj stvarnoj primarnoj potrošnji energije, neovisno o geografskoj lokaciji, dodijeljena je *Klasa 1 – energetski neučinkovita zgrada* zbog značajne potrošnje energije.

U nastavku je detaljno prikazan proces transformacije varijable *Prosječna trogodišnja potrošnja energija (kWh/m²)* prema prethodno navedenim koracima te postupak dodjeljivanja *Klase (Klasa 0 i Klasa 1)* prikazan je na slici 22.

Slika 22 Definiranje varijable Klase prema stvarnoj primarnoj potrošnji energije

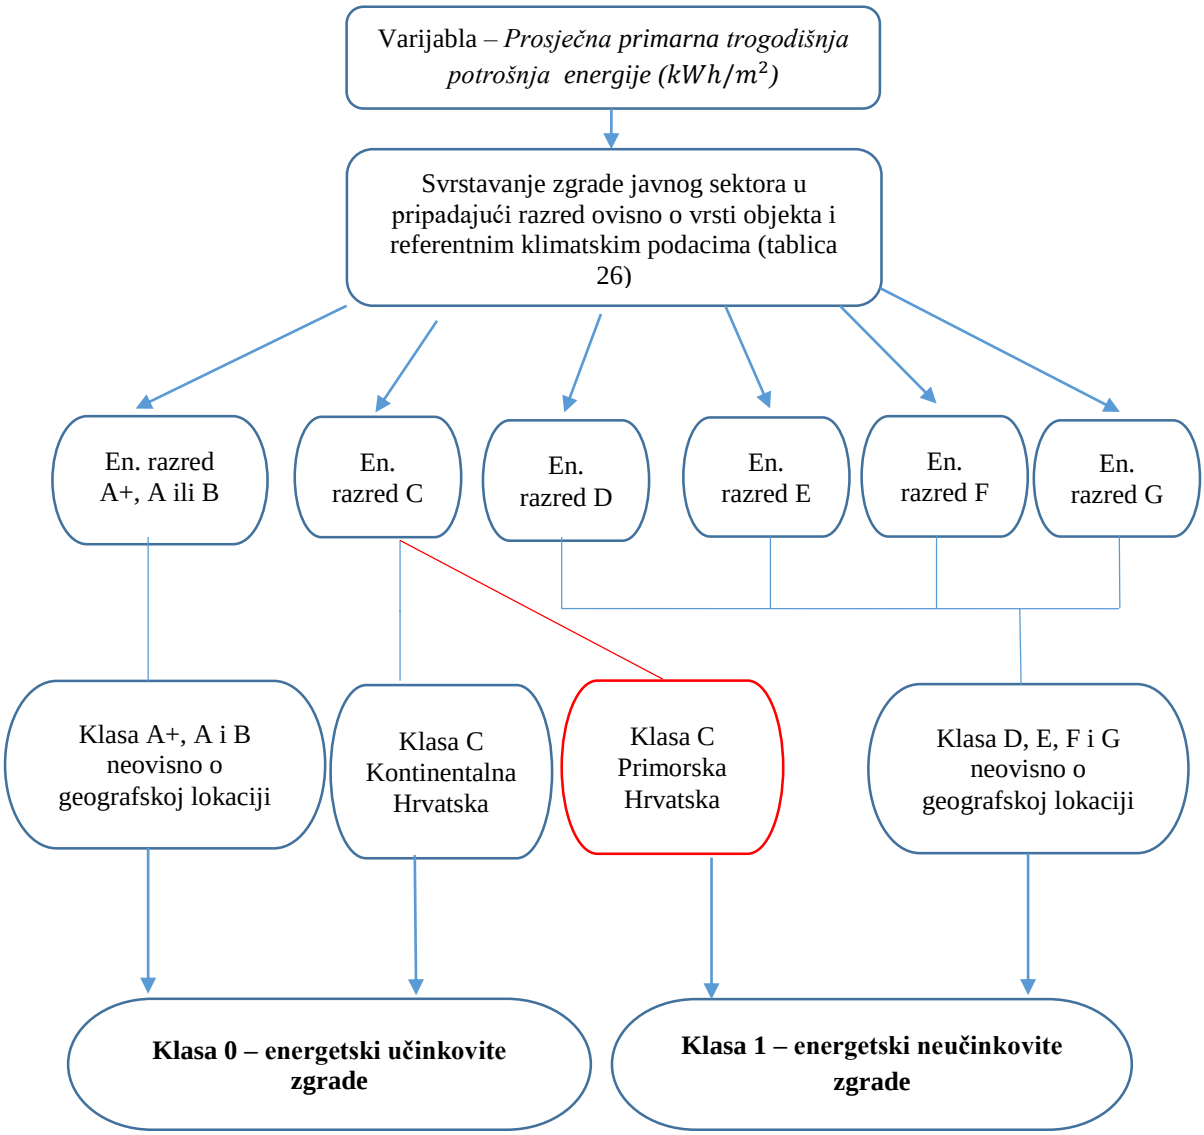

Izvor: Izrada autora

U procesu pripreme podataka za svaku zgradu javnog sektora izračunata je *Prosječna trogodišnja potrošnja energije izražena u kWh/m²*. Temeljem varijable *Prosječna trogodišnja*

potrošnja energije izražena u kWh/m² i u ovisnosti o namjeni zgrade javnog sektora (*administrativna, obrazovna, bolnica, sportska dvorana, ostale nestambene*) te referentnim klimatskim podacima (*kontinentalna ili primorska Hrvatska*) prvi korak u izradi ciljne varijable *Klasa* je svakoj zgradi javnog sektora pridružiti pripadajuću energetsku klasu ekvivalentnu propisanim energetskim razredima za potrošnju specifične godišnje primarne energije, E_{prim} izraženoj u kWh/m²a, a koje su definirane *Pravilnikom o energetskom pregledu zgrade i energetskom certificiranju*. Propisani energetski razredi za specifičnu godišnju primarnu energiju izraženi u kWh/m²a prikazani su u tablici 26.

Klasifikacija zgrada javnog sektora u razrede prema podacima iz tablice 26 koristila se kao usmjerenje za definiranje energetskih razreda te ne mora nužno biti ista klasifikacija što u ovom radu nije ni bilo moguće postići s obzirom na korištene podatke.

Tablica 26 Specifična godišnja primarna energija, E_{prim} kWh/m²a

E_{prim} (kWh/m^2a)	Uredska		Obrazovna		Bolnica		Sportska dvorana		Ostale nestambene	
Energetski razred	*K*	*P*	*K*	*P*	*K*	*P*	*K*	*P*	*K*	*P*
A+	≤ 35	≤ 25	≤ 55	≤ 55	≤ 250	≤ 250	≤ 210	≤ 150	≤ 80	≤ 50
A	> 35 ≤ 55	> 25 ≤ 50	> 55 ≤ 60	> 55 ≤ 58	> 250 ≤ 275	> 250 ≤ 275	> 210 ≤ 305	> 150 ≤ 160	> 80 ≤ 115	> 50 ≤ 75
B	> 55 ≤ 70	> 50 ≤ 70	> 60 ≤65	> 58 ≤ 60	> 275 ≤ 300	> 275 ≤ 300	> 305 ≤ 400	> 160 ≤ 170	> 115 ≤ 150	> 75 ≤ 100
C	> 70 ≤ 100	> 70 ≤ 90	> 65 ≤ 125	> 60 ≤ 120	> 300 ≤ 345	> 300 ≤ 325	> 400 ≤ 465	> 170 ≤ 225	> 150 ≤ 280	> 100 ≤ 225
D	> 100 ≤ 125	> 90 ≤ 110	> 125 ≤ 175	> 120 ≤ 175	> 345 ≤ 395	> 325 ≤ 350	> 465 ≤ 530	> 225 ≤ 280	> 280 ≤ 410	> 225 ≤ 350
E	> 125 ≤ 155	> 110 ≤ 140	> 175 ≤ 220	> 175 ≤ 220	> 395 ≤ 495	> 350 ≤ 440	> 530 ≤ 665	> 280 ≤ 350	> 410 ≤ 515	> 350 ≤ 435
F	> 155 ≤ 190	> 140 ≤ 165	> 220 ≤ 265	> 220 ≤ 265	> 495 ≤ 590	> 440 ≤ 525	> 665 ≤ 795	> 350 ≤ 415	> 515 ≤ 615	> 435 ≤ 520
G	> 190	>165	> 265	> 265	> 590	> 525	> 795	> 415	> 615	> 520

Izvor: Izrada autora – prilagođeno prema Pravilniku o energetskom pregledu zgrade i energetskom certificiranju (Pravilnik, NN 88/2017-2093)

Postojeći Pravilnik iz izračuna *Specifične godišnje primarne energije*, E_{prim} u pojedinim nestambenim zgradama isključuje potrošnju pojedinog tehničkog sustava kao što je primjerice potrošnja energije za potrebe rasvjete, pripreme tople vode i sl. Definirani tehnički sustavi za proračun primarne energije za referentne klimatske podatke za pojedine vrste zgrade prikazani su u tablici 27.

Tablica 27 Definirani tehnički sustavi za proračun primarne energije za referentne klimatske podatke za pojedine vrste zgrade

Vrsta zgrade	Sustav grijanja	Sustav hlađenja	Sustav pripreme PTV-a	Sustav meh. ventilacije i klimatizacije	Sustav rasvjete
Uredske zgrade	Da	Da	Ne	Uzima se u obzir ako postoji	Da
Zgrade za obrazovanje	Da	Ne	Ne		Da
Bolnice	Da	Da	Da		Da
Sportske dvorane	Da	Da	Da		Da
Ostale nestambene zgrade	Da	Ne	Ne		Da

Izvor: Izrada autora – prilagođeno prema Metodologiji provođenja energetskog pregleda zgrada 2021.

U ovoj doktorskoj disertaciji cilj je napraviti model koji će što točnije klasificirati zgrade javnog sektora prema njihovoj stvarnoj, ukupnoj potrošnji primarne energije te iz potrošnje zgrada javnog sektora nisu isključeni tehnički sustavi prikazani u prethodnoj tablici 27 s obzirom na to da iz podataka dostupnih u ISGE sustava to nije bilo moguće utvrditi.

Zbog velikog broja slučajeva u nastavku prikazan je postupak dodjeljivanja energetskog razreda zgradi javnog sektora u varijabli *Klasa* na primjeru četiriju zgrada javnog sektora (tablica 28). U alatu R na isti način dodijeljeni su energetski razredi za 2192 zgrade javnog sektora.

Tablica 28 Klasificiranje zgrade javnog sektora prema stvarnoj potrošnji energije po kWh/m^2

Objekt	Potrošnja po kWh/m^2	Regija	Tip objekta	Klasa 1. korak	Klasa – izlazna varijabla
Objekt 1	177.9	Kontinentalna	Zdravstvena ustanova	A	**0**
Objekt 2	169.78	Primorska	Obrazovna ustanova	D	**1**
Objekt 3	80.64	Kontinentalna	Uredska zgrada	C	**0**
Objekt 4	644.72	Kontinentalna	Uredska zgrada	G	**1**

Izvor: Izrada autora

U zadnjem koraku, prethodno prikazani energetski razredi definirani prema stvarnoj potrošnji energije podijeljeni su u dvije klase – *Klasu 0* koja je obuhvatila zgrade javnog sektora čija je stvarna potrošnja energije energetskog razreda A+, A, B ili C razreda (C razred ako se radi o zgradi smještenoj u kontinentalnoj Hrvatskoj) dok su *Klasom 1* obuhvaćene zgrade javnog sektora čija je stvarna potrošnja energije energetskog razreda C (ako se radi o zgradi smještenoj u primorskom dijelu Hrvatske) te energetski razredi D, E, F i G neovisno o geografskoj lokaciji.

Izradom ovog modela želi se omogućiti klasifikacija zgrada u dvije skupine: dobrih energetskih svojstava i loših energetskih svojstava kako bi korisnik ISGE sustava mogao na inteligentan način procijeniti energetsko stanje zgrade, ali i kako bi provoditelji programa energetske obnove mogli identificirati izrazito energetsko neučinkovite zgrada te pokrenuti propisane procedure za energetsku obnovu zgrada. Glavni je cilj omogućiti prepoznavanje energetski neučinkovitih zgrada javnog sektora.

Podjelom zgrada prema energetskom razredu stvarne potrošnje energije pripremljena je varijabla *Klasa* koja predstavlja ciljnu, odnosno izlaznu varijablu modela strojnog učenja. Dobivena struktura varijable *Klasa* u ukupnom uzorku od 2192 zgrada javnog sektora prikazana je na slici 23.

Slika 23 Struktura ciljne varijable Klasa

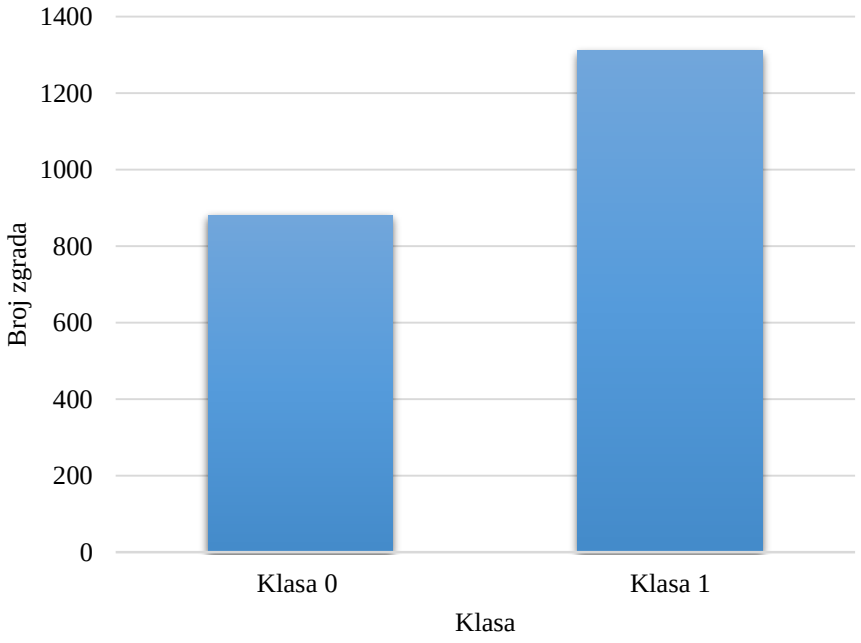

Izvor: Izrada autora

U ukupnom uzorku od 2192 slučaja, *Klasa 0* broji 881 slučaj (zgrada javnog sektora) dok *Klasa 1* broji 1312 slučajeva (zgrada javnog sektora). Zastupljenost *Klase 1* u ukupnom je uzorku 59,81 %, dok je zastupljenost *Klase 0* 40,19 %.

Definiranjem varijable koja predstavlja ciljnu, izlaznu varijablu završen je proces pripreme podataka započet u prethodnom poglavlju te su napravljeni preduvjeti za izradu modela za klasifikaciju zgrada javnog sektora. *Algoritmom 1* prikazan je sažetak napravljenog u fazi predprocesiranja i pripreme podataka (slika 24).

Slika 24 Algoritam predprocesuiranja i pripreme podataka i varijable cilja

Algoritam 1 Predprocesiranje podataka

Ulaz: početni skup podataka - matrica $X \in R^{m \cdot n}$

1. Spajanje i transformacija baza o uporabnim i konstrukcijskim podacima te potrošnji energije.
2. Identifikacija slučajeva x_{ij} $(i, j \in N,\ i \leq m, j \leq n)$ s nedostajućim vrijednostima.
3. Primjena *Algoritma za čišćenje građevinskih i uporabnih podataka*.
4. Isključivanje varijabli s više od 70 % nedostajućih slučajeva.
5. Priprema izlazne varijable *Klasa*.
   Cilj 1: pripremljena matrica podataka – korištena za izradu Modela 1 - model uključuje sve varijable u ulaznom prostoru
6. Selekcija varijabli – primjena filter metode: χ2 test i korelacija.
7. **Cilj 2: pripremljena matrica podataka - korištena za izradu Modela 2 –** varijable selektirane putem χ2 testa i korelacije.
8. Selekcija varijabli korištenjem metode omotača
   Cilj 3: pripremljena matrica podataka - korištena za izradu Modela 3 – Boruta model

Izvor: Izrada autora prema Zekić-Sušac, M., Has, A., & Knežević, M. (2021). Predicting energy cost of public buildings by artificial neural networks, CART, and random forest. *Neurocomputing*, 223-233

Prvih pet koraka u Algoritmu 1 sažimaju učinjeno u fazi pripreme i predprocesiranja podataka, odnosno pripremu podataka za izradu modela strojnog učenja za klasifikaciju stvarne potrošnje energije. Napravljena su tri modela koja se razlikuju po broju varijabli u ulaznom prostoru. Model 1 u ulaznom prostoru uključuje sve varijable, dok Model 2 i Model 3 u ulaznom prostoru uključuju reducirani broj varijabli dobiven korištenjem metoda selekcije varijabli.

4.2.2. Selekcija varijabli

Velik broj varijabli u ulaznom prostoru utječe na vrijeme potrebno za učenje modela, računalne resurse, ali i na uspješnost modela. Selekcijom varijabli nastoji se smanjiti broj varijabli u ulaznom prostoru na način da se iz ulaznog prostora isključuju varijable koje nemaju značajan utjecaj na ciljnu varijablu. Značajnost pojedine varijable procjenjuje se metodama za selekciju varijabli. Metode za selekciju varijabli dijele se na *nadzirane* (poznata je ciljna varijabla) i *nenadzirane* metode (ciljna varijabla nije poznata) (Wang i suradnici, 2015). Radi velikog broja varijabli u ulaznom prostoru i poboljšanja točnosti modela napravljena je selekcija varijabli korištenjem nadziranih metoda. Selekcijom varijabli dobiven je podskup koji predstavlja ulazne vrijednosti u *Modelu 2* i *Modelu 3*. U nadziranu selekciju varijabli ubrajaju se filter metode (engl. *Filter feature selection methods),* metode omotača (engl. *Wrapper Methods*) i ugrađene metode (engl. *Embedded Methods)* (Mehmood i suradnici, 2012). Filter metode neovisne su o algoritmima strojnog učenja, a varijable biraju se na temelju rezultata u različitim statističkim testovima u ovisnosti s ciljnom (izlaznom) varijablom (Kursa i Rudnicki, 2010). U filter metode ubrajaju se različite statističke metode kao što su korelacije (*Pearsonova korelacija, Spearmanova korelacija, Kendallova udaljenost*), $\chi 2$ test, analiza varijance (ANOVA), odnosno odabir ovisi o tipu podataka ulaznih varijabli te o tipu izlazne varijable (Venkatesh i Anuradha, 2019). Na slici 25 prikazan je pregled statističkih metoda za selekciju varijabli ovisno o tipu ulaznih i izlazne varijable.

Slika 25 Odabir statističkog testa ovisno o tipu varijable

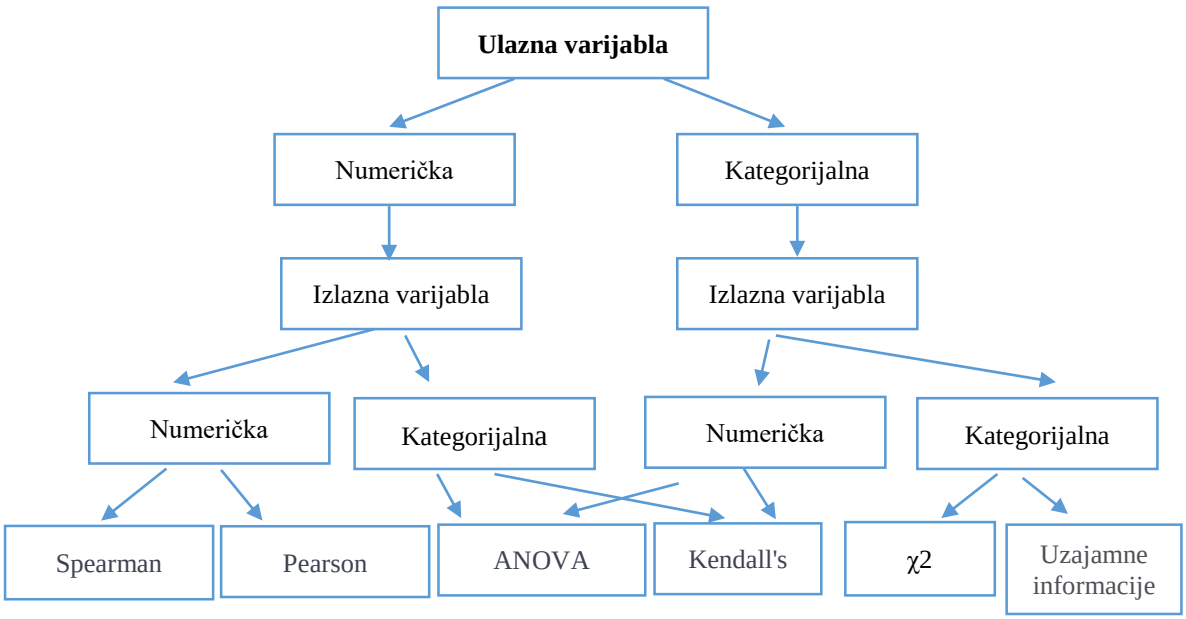

Izvor: Brownlee, J. (2019) How to Choose a Feature Selection Method for Machine Learning, Machine Learning Mastery

U ovom istraživanju, zavisna je varijabla kategorijalnog tipa (*Klasa 0* i *Klasa 1*). Međutim, u ulaznom prostoru od 61 varijable njih 55 imaju kontinuirane vrijednosti (numeričke) te su 6 varijabli u ulaznom prostoru kategorijalnog tipa. Ulazne varijable kontinuiranog tipa selektirane su putem korelacije, dok se za selekciju kategorijalnih varijabli koristio $\chi 2$ test. Varijable s visokom korelacijom i ovisnošću isključene su iz uzorka, a dobiveni podskup varijabli čini varijable u ulaznom prostoru za *Model 2*.

Metoda omotača korištena je za izradu drugog podskupa varijabli koje predstavljaju varijable u ulaznom prostoru *Modela 3*. U metodi omotača proces selekcije varijabli zasniva se na algoritmu strojnog učenja na način da se odabiru sve moguće kombinacije varijabli te ocjenjuju prema odabranoj metrici ocjenjivanja (Nnamoko i suradnici, 2014). Metrika ocjenjivanja ovisi o vrsti problema. U slučaju regresijskog problema to može biti p vrijednosti, R-kvadrat, prilagođeni R^2 , dok se za klasifikacijski tip problema koriste pokazatelji točnosti, preciznosti, opoziva te ROC krivulja (Venkatesh i Anuradha, 2019). Na temelju kriterija ocjenjivanja odabire se kombinacija varijabli koja daje optimalni rezultati za korišteni algoritam strojnog učenja (Venkatesh i Anuradha, 2019).

Metode omotača vrše selekciju varijabli kroz nekoliko standardnih koraka (Venkatesh i Anuradha, 2019). U prvom koraku odabire se podskup varijabli primjenom metoda pretraživanja koje mogu biti selekcija unaprijed (engl. *Forward Feature Selection*), selekcija unatrag (engl. *Backward Feature Elimination*), iscrpna selekcija (engl. *Exhaustive Feature Selection)* te dvosmjerno pretraživanje (engl. *Bidirectional Search*). U selekciji unaprijed polazi se od praznog modela i dodaje se jedna po jedna varijabla te se promatra utjecaj na ciljnu varijablu, dok selekcija unatrag označava suprotno, početno su obuhvaćene sve varijable u ulaznom prostoru nakon čega se eliminira jedna po jedna te se promatra utjecaj na ciljnu varijablu (Venkatesh i Anuradha, 2019). Drugi korak dolazi nakon odabira podskupa varijabli, u njemu se gradi model strojnog učenja te se odabrani algoritam strojnog učenja trenira na prethodno odabranom podskupu varijabli. U trećem koraku, prethodno kreirani model evaluira se odabranom metrikom (Venkatesh i Anuradha, 2019). Nakon toga, proces započinje iznova novim podskupom varijabli. Proces se zaustavlja kada se dostignu postavljeni predefinirani kriteriji (smanjenje performansi modela, povećanje performansi modela, dostizanje unaprijed definiranog broja varijabli i sl.) (Venkatesh i Anuradha, 2019).

Za selekciju varijabli korišten je algoritam *Boruta*. Algoritam *Boruta* klasifikacijski je algoritam slučajne šume. Kursa i Rudnicki (2010) opisali su postupak selekcije varijabli pomoću algoritma Boruta koji slijedi u nastavku. Inicijalni skup podataka duplicira se i nasumično se miješaju vrijednosti u svakom stupcu kako bi se otklonila korelacija s izlaznom varijablom. Duplicirane varijable nazivaju se i varijable sjene (engl. *shadow variable*). Nakon toga, na novom skupu podataka koji uključuje inicijalne varijable i varijable sjene primjenjuje se klasifikator slučajnih šuma i računa se Z vrijednost. Nadalje, algoritam provjerava imaju li inicijalne varijable veću važnost, odnosno ima li varijabla veću Z vrijednost od maksimalne Z vrijednosti svoje varijable u sjeni i od najbolje varijable u sjeni. U svakoj iteraciji, algoritam uspoređuje Z vrijednost pomiješanih varijabli sjene i izvornih varijabli kako bi se vidjelo jesu li potonje bile bolje od prvih. Varijable koji imaju važnost znatno nižu od maksimalne Z vrijednosti među varijablama sjene uklanjanju se, dok se varijable koje imaju važnost znatno veću od maksimalne Z vrijednosti među varijablama sjene smatraju važnima. Pojednostavljeno, algoritam pokušava potvrditi važnost varijable usporedbom s varijablama sjene. Postupak se ponavlja dok se ne odredi važnost svih varijabli ili dok se ne postignu prethodno postavljene granice slučajnih šuma (Kursa i Rudnicki, 2010).

Model 1 u ulaznom prostoru obuhvaća sve varijable. Ulazne varijable za Model 2 selektirane su na temelju korelacija i χ^2 testa u *Modelu 2* (paket Fselector u alatu R) te podskup varijabli dobivenih na temelju algoritma Boruta (paket Boruta u alatu R) predstavlja ulaz u *Model 3*. Selektirane varijable filter metodom i metodom omotača prikazane su u tablici 29 *Selekcija varijabli*. Zbog velikog broja varijabli tablica 29 nalazi se u prilogu.

Selekcija varijabli napravljena filter metodom identificirala je 25 značajnih varijabli. Metodom omotača, odnosno algoritmom Boruta, identificirane su 41 značajne varijable. U nastavku slijedi prikaz izgradnje sva tri modela za klasificiranje zgrada javnog sektora prema potrošnji stvarne energije.

4.2.3. Izgradnja modela za klasificiranje zgrada javnog sektora prema stvarnoj potrošnji energije

Izrada modela strojnog učenja, neovisno o metodi, sadrži nekoliko međusobno povezanih koraka. Svaki korak određuje smjer daljnje izgradnje modela, ali i utječe na konačnu uspješnost modela. U ovom potpoglavlju prikazat će se proces izgradnje modela temeljenog na dubokim neuronskim mrežama za klasificiranje zgrada javnog sektora prema stvarnoj potrošnji primarne

energije, odnosno korišteni parametri za izradu modela, te će svaki od koraka u izgradnji modela biti dodatno pojašnjen. Na slici 26 prikazani su koraci u izgradnji modela neuronske mreže prateći ranije prikazani dijagram.

Slika 26 Koraci u izgradnji modela neuronske mreže u provedenom istraživanju

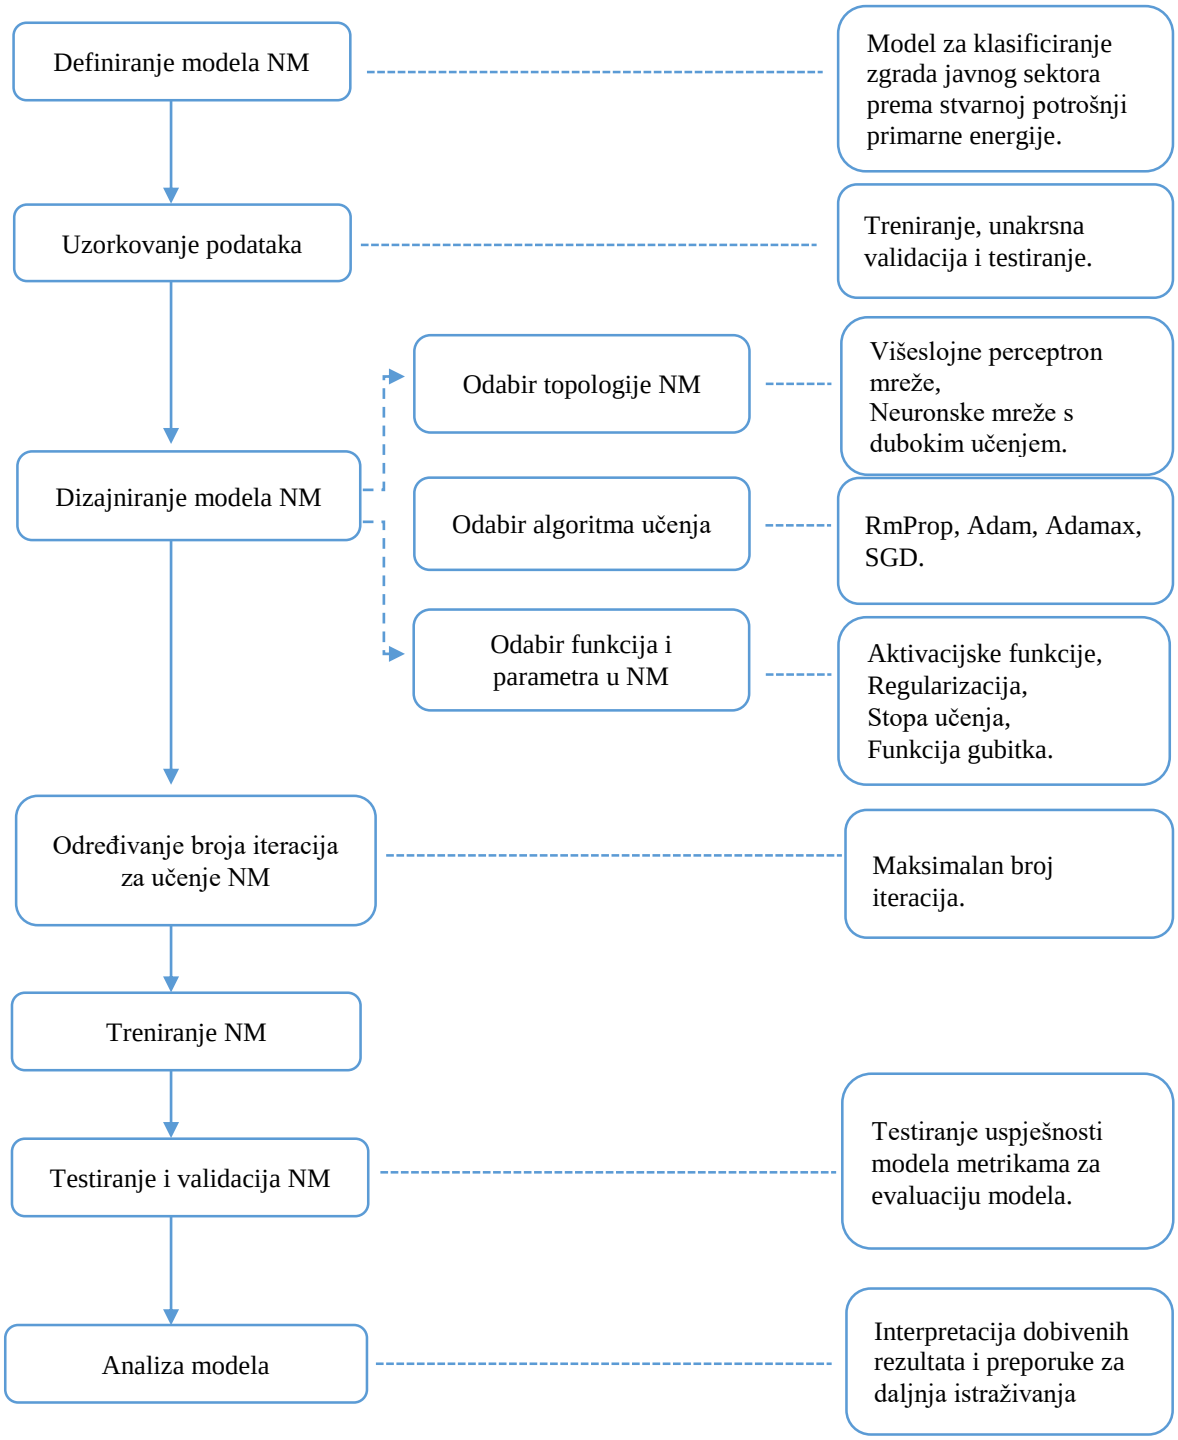

Izvor: Izrada autora

Tip problema koji se modelira utječe na odabir parametra, hiperparametra te metrika uspješnosti u procesu modeliranja. Pripremljena izlazna varijabla u ovom radu ukazuje na tip problema kojim se bavi ova doktorska disertacija, a to je klasifikacijski problem.

Cilj je napraviti model koji će klasificirati zgrade u odnosu na njihovu stvarnu primarnu potrošnju u jednu od dvije predefinirane kategorije: *Klasu 0* koja označava zgrade koje prema svojoj stvarnoj potrošnji energije pripadaju energetskom razredu A+, A, B ili C, ako je zgrada u kontinentalnom dijelu Hrvatske te *Klasu 1* koja označava zgrade koje prema svojoj stvarnoj potrošnji energije pripadaju energetskom razredu C (ako je zgrada smještena u primorskoj Hrvatskoj) te D, E, F ili G bez obzira na geografsku lokaciju. Model se temelji na metodi dubokih neuronskih mreža. Ova metoda odabrana je kao odgovor na postavljena istraživačka pitanja, kvalitetu podataka o zgradama javnog sektora te problem koji se modelira.

Uzorak od 2192 zgrade javnog sektora podijeljen je na tri poduzorka pri čemu svaki poduzorak predstavlja jednu fazu rada umjetnih neuronskih mreža: poduzorak za treniranje, unakrsnu validaciju i testiranje. U alatu koji se koristio za izradu modela parametar unakrsne validacije određuje se unutar uzorka za treniranje. Struktura uzorka prikazana je u tablici 30.

Tablica 30 Struktura uzorka za modeliranje

Uzorak	**Broj slučajeva u uzorku**	
Treniranje i Unakrsna validacija	1735 (80 %)	Treniranje: 1475 (85 % od 1735)
		Unakrsna validacija: 260 (15 % od 1735)
Test	439 (20 %)	
Ukupno	2192 (100 %)	

Izvor: Izrada autora

Iz tablice 30 vidljivo je kako se najveći broj slučajeva nalazi u poduzorku za treniranje, odnosno 80 % ukupnog uzorka. Važnost faze treniranja objašnjena je u prethodnim poglavljima. Od poduzorka za treniranje dio slučajeva izdvojen je u poduzorak za unakrsnu validaciju (15 % od uzorka za treniranje) s ciljem optimizacije vremena i parametara prilikom procesa učenja mreže. Konačna uspješnost sva tri modela ocjenjena je na poduzorku za testiranje kojeg čini 439 slučaja, odnosno 20 % ukupnog uzorka.

Prije samog procesa modeliranja napravljena je normalizacija kontinuiranih varijabli u ulaznom prostoru pomoću *min – max* metode normalizacije temeljem slijedeće formule:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \tag{13}$$

u kojoj x predstavlja skup promatranih vrijednosti prisutnih u x, x_{min} minimalne vrijednosti u x te x_{max} maksimalne vrijednosti u x. Procesom normalizacije vrijednosti varijabli svedene su na raspon od 0 do 1.

Za sva tri modela testirane su u nastavku navedene arhitekture umjetne neuronske mreže te parametri i hiperparametri s ciljem utvrđivanja najboljeg modela. Modeliranje dubokih neuronskih mreža u paketu *Keras* provod se u nekoliko osnovnih koraka:

- definiranje modela (engl. *Defining*),
- sastavljanje modela (engl. *Compile*),
- podešavanje modela (engl. *Fitting*),
- evaluacija i predikcija.

U prvom koraku definira se broj skrivenih slojeva u neuronskoj mreži, dimenzionalnost ulaza u prvom sloju, broj neurona u izlaznom sloju, aktivacijske funkcije koje se koriste u slojevima neuronske mreže te inicijalne težine neuronske mreže. Testirane su različite dubine neuronske mreže, odnosno neuronske mreže s jednim, dva, tri te četiri skrivena sloja. Dimenzionalost ulaza u pojedinom modelu ovisila je o broju ulaznih varijabli.

Model 1 obuhvaća 62 ulazne varijable u ulaznom prostoru i one čine 72 ulazna neurona u ulaznom sloj neuronske mreže. Svaka kontinuirana varijabla predstavlja jedan neuron, dok kod kategorijalnih varijabli svaka kategorija u pojedinoj varijabli također se promatra kao poseban neuron što dovodi do većeg broja neurona u ulaznom prostoru. U **Modelu 2** ulazni prostor obuhvatio je 34 neurona dok je u **Modelu 3** ulazni prostor obuhvatio 48 neurona. Broj neurona u izlaznom sloju predstavlja izlaznu varijablu modela te se u ovom radu u izlaznom sloju nalaze dva neurona gdje svaki od neurona predstavlja jednu izlaznu klasu (*Klasa 0* predstavlja energetski učinkovitu zgradu i *Klasa 1* koja predstavlja energetski neučinkovitu zgradu). Broj neurona u ulaznom i izlaznom sloju unaprijed je određen, ovisno o broju varijabli koje se uključuju u model. Broj neurona u skrivenim slojevima proizvoljan je te s ciljem dobivanja što veće točnosti modela testirano je od 1 do 130 neurona u svakom skrivenom sloju, ovisno o

arhitekturi mreže. Testirane su i različite aktivacijske funkcije (*sigmoidna funkcija, tvrda sigmoidna funkcija, tangens funkcija, ReLu funkcija*), dok je u izlaznom sloju korištena sigmoidna aktivacijska funkcija.

U drugom koraku prethodno definirani model nadograđuje se pomoću funkcije sastavljanje (engl. *compile()*) definiranjem funkcije gubitka, odabirom optimizacijskog algoritma te metrike za ocjenu uspješnosti. S obzirom na to da je u ovoj doktorskoj disertaciji izlazna varijabla binarna (*Klasa 0* i *Klasa 1*) za funkciju gubitka korištena je binarna unakrsna entropija (engl. *binary crossentropy).* Prilikom izrade modela s ciljem minimiziranja funkcije gubitka testirane su slijedeće optimizacijske tehnike: *Adam, Adamax, Rmprop* i *Sgd*.

U trećem koraku model se podešava (engl. *Fitting)* pomoću funkcije *fit().* Definira se uzorak za treniranje modela, broj epoha za treniranje, uzorak za unakrsnu validaciju, stopa učenja modela te pravilo zaustavljanja s ciljem sprečavanja pretreniranja modela. Broj epoha definirao se argumentom epoha (engl. *epoch)* koji predstavlja broj epoha u kojima se odvija učenje neuronske mreže. U svim modelima korišteno je 200 epoha. Veličina serije (engl. *batch size*) je hiperparametar unutar funkcije *fit()* koji predstavlja mini stohastički gradijent opadanja, odnosno uzorak za treniranje dijeli se na poduzorke te se za svaki poduzorak (skupinu) računa gradijent opadanja nakon čega se ažuriraju parametri modela. Argument izbacivanje (engl. *dropout*) služio je za sprječavanje pretreniranja mreže i vrijednost tog parametra bila je od 0,5 do 0,8.

Četvrti korak u modeliranju dubokih neuronskih mreža pomoću paketa Keras označava fazu evaluacije koja se vrši putem funkcije *evaluate(),* odnosno prethodno treniran model testira se na testnim podacima – podacima na kojima mreža nije ranije učila te se rade predikcije. U ovom koraku izračunate su metrike za ocjenu uspješnosti modela: *stopa točnosti klasifikacije, stope točnosti klasifikacije za obje klase, preciznost, odaziv, F1 ocjena* i *AUC.* Prethodno opisana procedura modeliranja korištena u sva tri izgrađena modela može se sažeti Algoritmom 2 (slika 27).

Slika 27 Algoritam 2 Modeliranje neuronskih mreža

Algoritam 2 Modeliranje dubokih neuronskih mreža

Ulaz 1: sve varijable u ulaznom prostoru

1. Normalizacija podataka. Podjela uzorka na poduzorak za treniranje, testiranje, validaciju.
2. Treniranje, validacija, testiranje duboke neuronske mreže (DNN):

(a) Definiranje broja neurona u skrivenom sloju u rasponu od (1-130) *i=1* do *130*

(b) Definiranje sekvencionalnog DNN modela s jednim, dva, tri i četiri skrivena sloja:

(I) *skriveni sloj 1* s brojem skrivenih neurona raspona *i*, aktivacijska funkcija: sigmoidna, tvrda sigmoidna, ReLu i tangens funkcija,
optimizacijski algoritam: *Adam, Adamax, SGD i RMSProp*,
regularizacija težina – isključivanje (stopa = 0,8),

(II) *skriveni sloj 2* s brojem skrivenih neurona raspona *i*, aktivacijska funkcija: sigmoidna, tvrda sigmoidna, ReLu i tangens funkcija,
optimizacijski algoritam: *Adam, Adamax, SGD i RMSProp*
regularizacija težina – isključivanje (stopa = 0,8).

(III) *skriveni sloj 3* s brojem skrivenih neurona raspona *i*, aktivacijska funkcija: sigmoidna, tvrda sigmoidna, ReLu i tangens funkcija,
optimizacijski algoritam: *Adam, Adamax, SGD i RMSProp*
regularizacija težina – isključivanje (stopa = 0,8).

(IV) *skriveni sloj 4* s brojem skrivenih neurona raspona *i*, aktivacijska funkcija: sigmoidna, tvrda sigmoidna, ReLu i tangens funkcija,
optimizacijski algoritam: *Adam, Adamax, SGD i RMSProp*,
regularizacija težina – isključivanje (stopa = 0,8),

(V) *izlazni sloj* s 2 neurona (2 klase).

(c) Evaluacija modela na testnom uzorku, izračun predikcija

(d) Izračun stope točnosti klasifikacije, pokazatelja preciznosti, odaziva, F1 ocjene, AUC,

(e) Odabir modela

Rezultat 1: *DNN Model* 1 – sve varijable u ulaznom prostoru

Ulaz 2: varijable selektirane filter metodom – korelacija i χ^2

1. Ponavljanje koraka od 1 to 2 s varijablama definiranim *Ulazom 2*

Rezultat 2: *DNN Model 2*– filter metodom selektirane varijable u ulaznom prostoru

Ulaz 3: varijable selektirane metodom omotača – algoritam Boruta

1. Ponavljanje koraka od 1 to 2 s varijablama definiranim *Ulazom 3*

Rezultat 3: DNN Model 3– selektirane varijable u ulaznom prostoru metodom omotača

Izvor: Izrada autora prema Zekić-Sušac, M., Has, A., & Knežević, M. (2021). Predicting energy cost of public buildings by artificial neural networks, CART, and random forest. Neurocomputing, 223-233

Rezultati sva tri modela umjetne neuronske mreže za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji energije prikazani su u sljedećem potpoglavlju.

4.2.4. Rezultati modela strojnog učenja za klasificiranje zgrada javnog sektora prema potrošnji stvarne primarne energije

Testiranjem različitih dubina neuronske mreže (*jedan, dva, tri i četiri skrivena sloja*), različitog broja neurona u skrivenim slojevima, aktivacijskih funkcija (*sigmoidna, tvrda sigmoidna, tangens, ReLu)*, optimizacijskih algoritama (*Adam, Adamax, Nadam, RMSprop, SGD*) i ostalih parametra i hiperparametara predstavljenih u prethodnim potpoglavljima dobiveni su rezultati Modela 1, Modela 2 i Modela 3. Optimalni rezultati sva tri modela predstavljeni su u tablici 31.

Tablica 31 Optimalni rezultati Modela 1, Modela 2, Modela

Model	**Topologija mreže**	**Parametri modela**	**Vrednovanje modela**	
Model 1 – sve ulazne varijable				%
ANN – 1 skriveni sloja	78-*59*-2	ReLu aktivacijska funkcija, Adam optimizacijski algoritam Stopa učenja 0.01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	67,2
			Stopa točnosti klasifikacije za klasu 0	57,2
			Stopa točnosti klasifikacije za klasu 1	73,7
			Preciznost	72,6
			Opoziv	73,7
			F1 ocjena	73,1
			AUC	73,3
ANN – 2 skrivena sloja	78-*58-46*-46	ReLu aktivacijska funkcija, Adam optimizacijski algoritam Stopa učenja 0.01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	70,2
			Stopa točnosti klasifikacije za klasu 0	51,4
			Stopa točnosti klasifikacije za klasu 1	82,3
			Preciznost	72,3
			Opoziv	82,3
			F1 ocjena	77,0
			AUC	73,2
DNN – 3 skrivena sloja	78-*115-95-46*-2	ReLu aktivacijska funkcija, Adam optimizacijski algoritam Stopa učenja 0.01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	67,9
			Stopa točnosti klasifikacije za klasu 0	60,7
			Stopa točnosti klasifikacije za klasu 1	72,6

			Preciznost	73,9
			Opoziv	72,6
			F1 ocjena	73,2
			AUC	72,4
DNN – 4 skrivena sloja	*78-95-76-56-21-2*	ReLu aktivacijska funkcija, Adam optimizacijski algoritam Stopa učenja 0.01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	67,7
			Stopa točnosti klasifikacije za klasu 0	47,3
			Stopa točnosti klasifikacije za klasu 1	80
			Preciznost	70,3
			Opoziv	80
			F1 ocjena	75,2
			AUC	68,8
Model 2 – filter metoda za selekciju varijabli				
ANN – 1 skriveni sloj	34-*46*-1	ReLu aktivacijska funkcija, Adam optimizacijski algoritam Stopa učenja 0,01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	67,0
			Stopa točnosti klasifikacije za klasu 0	50,8
			Stopa točnosti klasifikacije za klasu 1	77,4
			Preciznost	70,8
			Opoziv	77,4
			F1 ocjena	
			AUC	69,9
ANN – 2 skrivena sloj	34- *56 -27* -1	Tangens aktivacijska funkcija, Adam optimizacijski algoritam Stopa učenja 0,01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	67,9
			Stopa točnosti klasifikacije za klasu 0	59,0
			Stopa točnosti klasifikacije za klasu 1	73,7
			Preciznost	73,4
			Opoziv	73,7
			F1 ocjena	73,5
			AUC	72,1
DNN – 3 skrivena sloja	34- *34 -20-17*-1	Tangens aktivacijska funkcija, Adam optimizacijski algoritam Stopa učenja 0,01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	67,2
			Stopa točnosti klasifikacije za klasu 0	58,0
			Stopa točnosti klasifikacije za klasu 1	72,6
			Preciznost	73,1
			Opoziv	72,6
			F1 ocjena	72,8
			AUC	71,6
DNN – 4 skrivena sloja	34- *93 -86-62* -32-2	ReLU aktivacijska funkcija, Adam optimizacijski algoritam Stopa učenja 0,01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	65,4
			Stopa točnosti klasifikacije za klasu 0	50,0

			Stopa točnosti klasifikacije za klasu 1	75,6
			Preciznost	69,8
			Opoziv	75,6
			F1 ocjena	72,6
			AUC	68,8
Model 3 – metoda omotača – BORUTA algoritam				
ANN – 1 skriveni sloja	48-*20*-2	Tangens aktivacijska funkcija, Adam optimizacijski algoritam Stopa učenja 0,01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	70,4
			Stopa točnosti klasifikacije za klasu 0	**60,9**
			Stopa točnosti klasifikacije za klasu 1	**76,7**
			Preciznost	75,0
			Opoziv	**76,7**
			F1 ocjena	**75,8**
			AUC	**73,8**
ANN – 2 skrivena sloja	48-*23*-*78*-2	Tangens aktivacijska funkcija, Adam optimizacijski algoritam Stopa učenja: 0,01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	69,9
			Stopa točnosti klasifikacije za klasu 0	65,3
			Stopa točnosti klasifikacije za klasu 1	72,9
			Preciznost	76,4
			Opoziv	72,9
			F1 ocjena	74,6
			AUC	73,6
DNN-Boruta – 3 skrivena sloja	48-*92*-*73* - *46*-2	Tangens aktivacijska funkcija, Nadam optimizacijski algoritam Stopa učenja 0,01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	71,1
			Stopa točnosti klasifikacije za klasu 0	52,6
			Stopa točnosti klasifikacije za klasu 1	83,0
			Preciznost	72,9
			Opoziv	83,1
			F1 ocjena	77,7
			AUC	74,3
DNN-Boruta – 4 skrivena sloja	46 -*116*-*92*-*76*-*56*-2	Tangens aktivacijska funkcija Adam optimizacijski algoritam Stopa učenja: 0,01	Ukupna stopa točnosti klasifikacije na uzorku za testiranje	70,2
			Stopa točnosti klasifikacije za klasu 0	43,2
			Stopa točnosti klasifikacije za klasu 1	87,2
			Preciznost	70,5
			Opoziv	87,2
			F1 ocjena	78,0
			AUC	70,6

Izvor: Izrada autora

Dubina neuronske mreže nije značajno pridonijela poboljšanju performansi. U tablici 32 izdvojene su topologije koje su ostvarile najbolje rezultate unutar svakog od modela.

Tablica 32 Usporedba metrika uspješnosti za Model 1, Model 2 i Model 3

Metrike uspješnosti	**Model 1** **78-*115*-*95*-*46*-2**	**Model 2** **34- *56* -*27* -1**	**Model 3** **48-*20*-2**
Ukupna stopa točnosti klasifikacije na uzorku za testiranje	67,9	67,9	**70,4**
Stopa točnosti klasifikacije za klasu 0	60,7	59,0	**60,9**
Stopa točnosti klasifikacije za klasu 1	72,6	73,7	**76,7**
Preciznost (%)	73,9	73,4	**75,0**
Opoziv (%)	72,6	73,7	**76,7**
F1 ocjena (%)	73,2	73,5	**75,8**
AUC (%)	72,4	72,1	**73,8**

Izvor: Izrada autora

Radi neravnomjerne zastupljenosti *Klase 0* i *Klase 1* stopa točnosti klasifikacije nije promatrana kao jedino mjerilo pri izboru najboljeg modela, odnosno pri izboru *Modela 1, Modela 2* i *Modela 3*. Prilikom ocjene uspješnosti modela vodilo se ciljem ovog istraživanja te svrhom predloženog modela, a to je identifikacija energetski neučinkovitih zgrada.

Cilj je modela identifikacija energetski loših zgrada stoga je i fokus na metrikama usmjerenim na uspješnost klasifikatora u prepoznavanju energetski loših zgrada. Svrstavanje energetski loših zgrada u energetski učinkovite zgrade uzrokuje veće troškove nego kod obrnute situacije. No pojedini modeli pokazali su vrlo visoku točnost klasifikacije energetski neučinkovitih zgrada (preko 80 %), međutim nisu uzeti u obzir jer su se pokazali izuzetno lošima u predviđanju energetski učinkovitih zgrada. Prilikom odabira optimalnog modela uzimale su se u obzir i stope točnosti klasifikacije po svakoj klasi te uvjet da klasifikator mora ostvarivati minimalno 60 % točnosti klasifikacije za klasu energetski učinkovitih zgrada. Model 2 temeljen na selekciji varijabli putem filter metode pokazao je najlošije performanse, dok je Model 3 ostvario najbolje rezultate i odabran je za daljnju analizu.

4.2.5. Analiza predloženog modela za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji energije

Najbolje performanse u klasifikaciji zgrada javnog sektora prema stvarnoj potrošnji primarne energije u provedenom istraživanju pokazao je Model 3 arhitekture ANN 48-20-2. Na slici 28 prikazana je arhitektura odabranog modela.

Slika 28 Arhitektura odabranog modela neuronske mreže Model 3

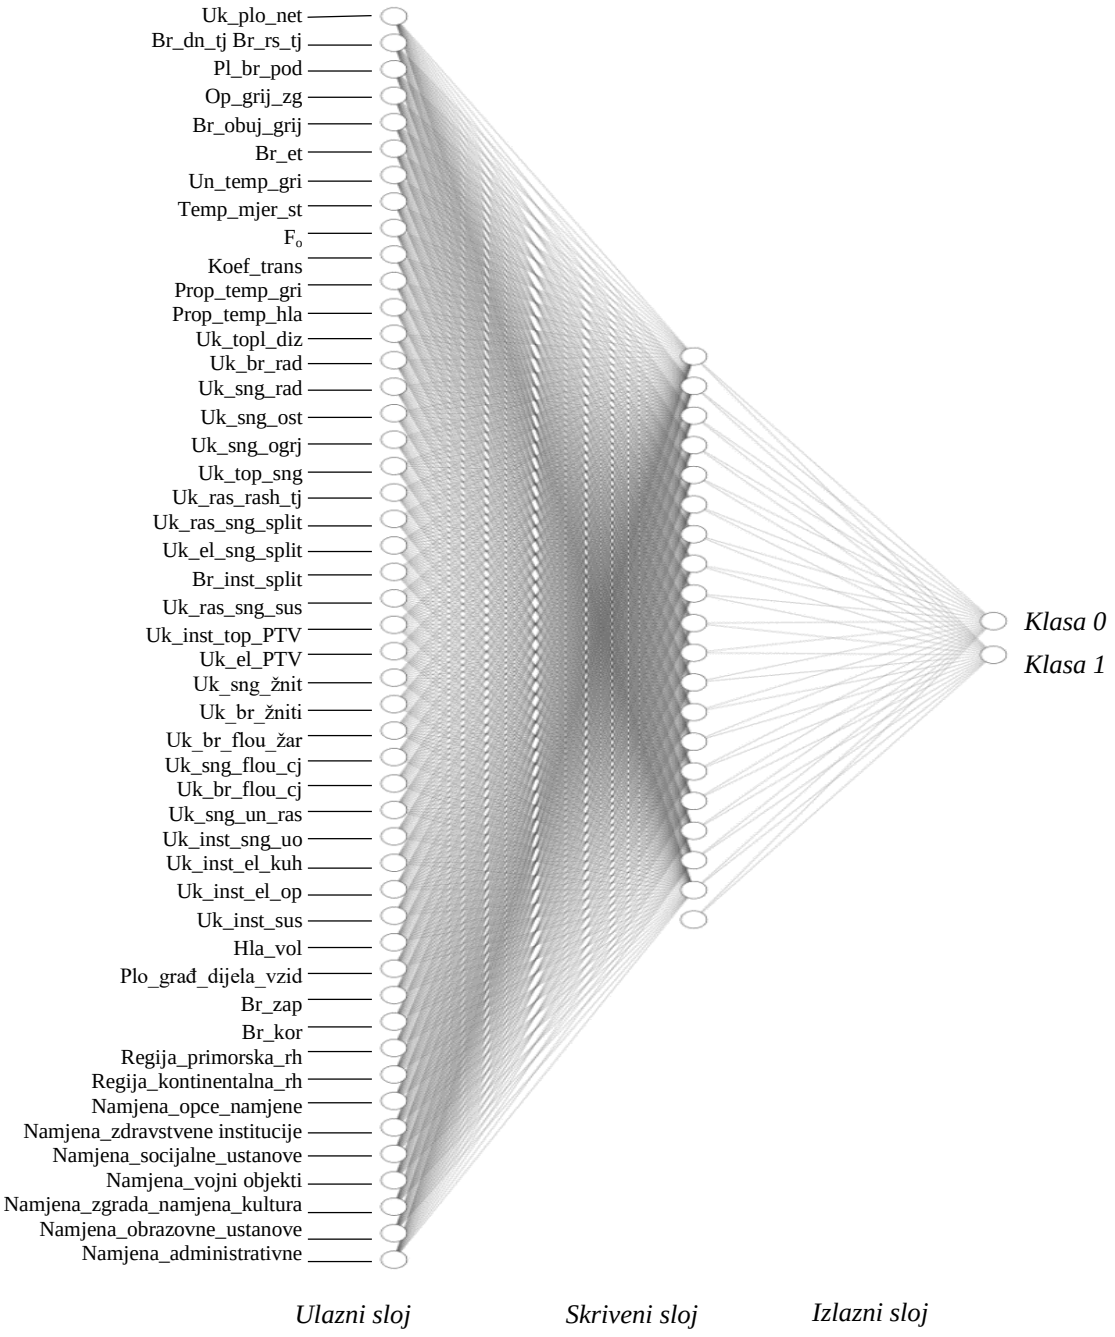

Izvor: Izrada autora

Arhitektura modela ukazuje na plitku umjetnu neuronsku mrežu koja se sastoji od tri sloja: ulaznog, jednog skrivenog sloja te izlaznog sloja. U prvom, ulaznom sloju nalazi se 48 neurona koji predstavljaju varijable ulaznom prostoru modela, u skrivenom sloju nalazi se 20 neurona te 2 neurona u izlaznom sloju koji predstavljaju *Klasu 0* (energetski učinkovite zgrade) i *Klasu 1* (energetski neučinkovite zgrade).

Rezultati odabranog *Modela 3* prikazani su u tablici 33.

Tablica 33 Prikaz najboljeg rezultata Modela 3

Arhitektura mreže	48-20-2
Broj parametara	1401
Optimizacijski algoritam	Adam
Aktivacijska funkcija	Tangens
Ukupna stopa točnosti klasifikacije na uzorku za testiranje (%)	70,4
Stopa točnosti klasifikacije za klasu 0(%)	60,9
Stopa točnosti klasifikacije za klasu 1 (%)	76,7
Preciznost (%)	75,0
Opoziv (%)	76,7
F1 ocjena (%)	75,8
AUC (%)	73,8

Izvor: Izrada autora

Optimizacijski algoritam kojim su ostvareni prikazani rezultati algoritam je *Adam* te *tangens-hiperbolična* aktivacijska funkcija, dok je u izlaznom sloju korištena *sigmoidna* funkcija.

Kroz matricu konfuzije prikazana je uspješnost modela po klasama (tablica 34) te je prikazana matrica konfuzije bila temelj za izračun navedenih metrika za ocjenu uspješnosti modela.

Tablica 34 Matrica konfuzije za odabrani model

	Stvarno		Ukupno
Predviđeno	**Klasa 1**	**Klasa 0**	
Klasa 1	**204**	68	272
Klasa 0	62	**105**	167
Ukupno	266	173	439

Izvor: Izrada autora

Matrica konfuzije dobivenog modela može se protumačiti na sljedeći način: *Klasi 1* koja predstavlja energetski neučinkovite zgrade u testnom uzorku pripadale su 266 zgrade, od toga je model neuronske mreže ispravno svrstao njih 266, dok je za 62 zgrade javnog sektora model pogrešno predvidio i označio ih kao energetski učinkovite zgrade. Stopa točnosti klasifikacije za *Klasu 1* iznosi 76,1 %. Kada se promatra *Klasa 0,* odnosno energetski učinkovite zgrade, može se zaključiti kako je od ukupno 173 zgrade javnog sektora koje su zaista bile energetski učinkovite model ispravno svrstao njih 105 u energetski učinkovite zgrade dok je kod 68 zgrada javnog sektora pogriješio i svrstao ih u energetski neučinkovite zgrade. Stopa točnosti klasifikacije za *Klasu 0* iznosi 60,9 %.

Omjer ispravno klasificiranih slučajeva u odnosu na ukupan broj slučaja daje pokazatelj *ukupne stope točnosti* klasifikacije koji u ovom modelu iznosi 70,4 %. Model ispravno prepoznaje 70,4 % slučajeva iz uzorka za testiranje (*uzorak na kojem model nije učio, prag* (engl. *threshold) = 0,6*). Pokazatelj *preciznosti* govori o omjeru između stvarno pozitivnih i svih pozitivno klasificiranih slučajeva. U ovom istraživanju pokazatelj preciznosti govori koliko je stvarno energetsko neučinkovitih zgrada bilo ispravno klasificirano u odnosu na ukupan broj zgrada koje su identificirane kao neučinkovite zgrada. Pokazatelj *preciznosti* iznosi 75 % što znači da kad model predvidi da je pojedina zgrada energetski neučinkovita to će biti ispravno u 75 % slučajeva.

Pokazatelj *odaziva* iznosi 76,7 % i govori o tome koliko je energetski neučinkovitih zgrada zaista identificirano kao energetski neučinkovite zgrade. F1 ocjena predstavlja harmonijsku sredinu između pokazatelja preciznosti i odziva te u dobivenom modelu ona iznosi 75,8 %.

Pokazatelj *AUC* ukazuje na vrijednost površine ispod ROC krivulje i u ovom istraživanju iznosi 73,8 %. Svi prikazani pokazatelji točniji su ako su im vrijednosti bliže 1, odnosno s većom točnosti predviđaju izlazne vrijednosti.

Analizom osjetljivosti istraženo je koje varijable imaju najveći utjecaj na predstavljeni model. Istražila se globalna značajnost pojedine varijable na model ali i važnost varijable na lokalnoj razini u predviđanju pojedine klase. Na slici 29 prikazana je značajnost ulaznih varijabli na model, odnosno na ciljnu varijablu. Crvenom linijom označena je pozitivna korelacija s izlaznom varijablom *Klasa*, dok crne linije označavaju negativnu korelaciju s izlaznom varijablom *Klasa.*

Slika 29 Utjecaj ulaznih varijabli na ciljnu varijablu modela

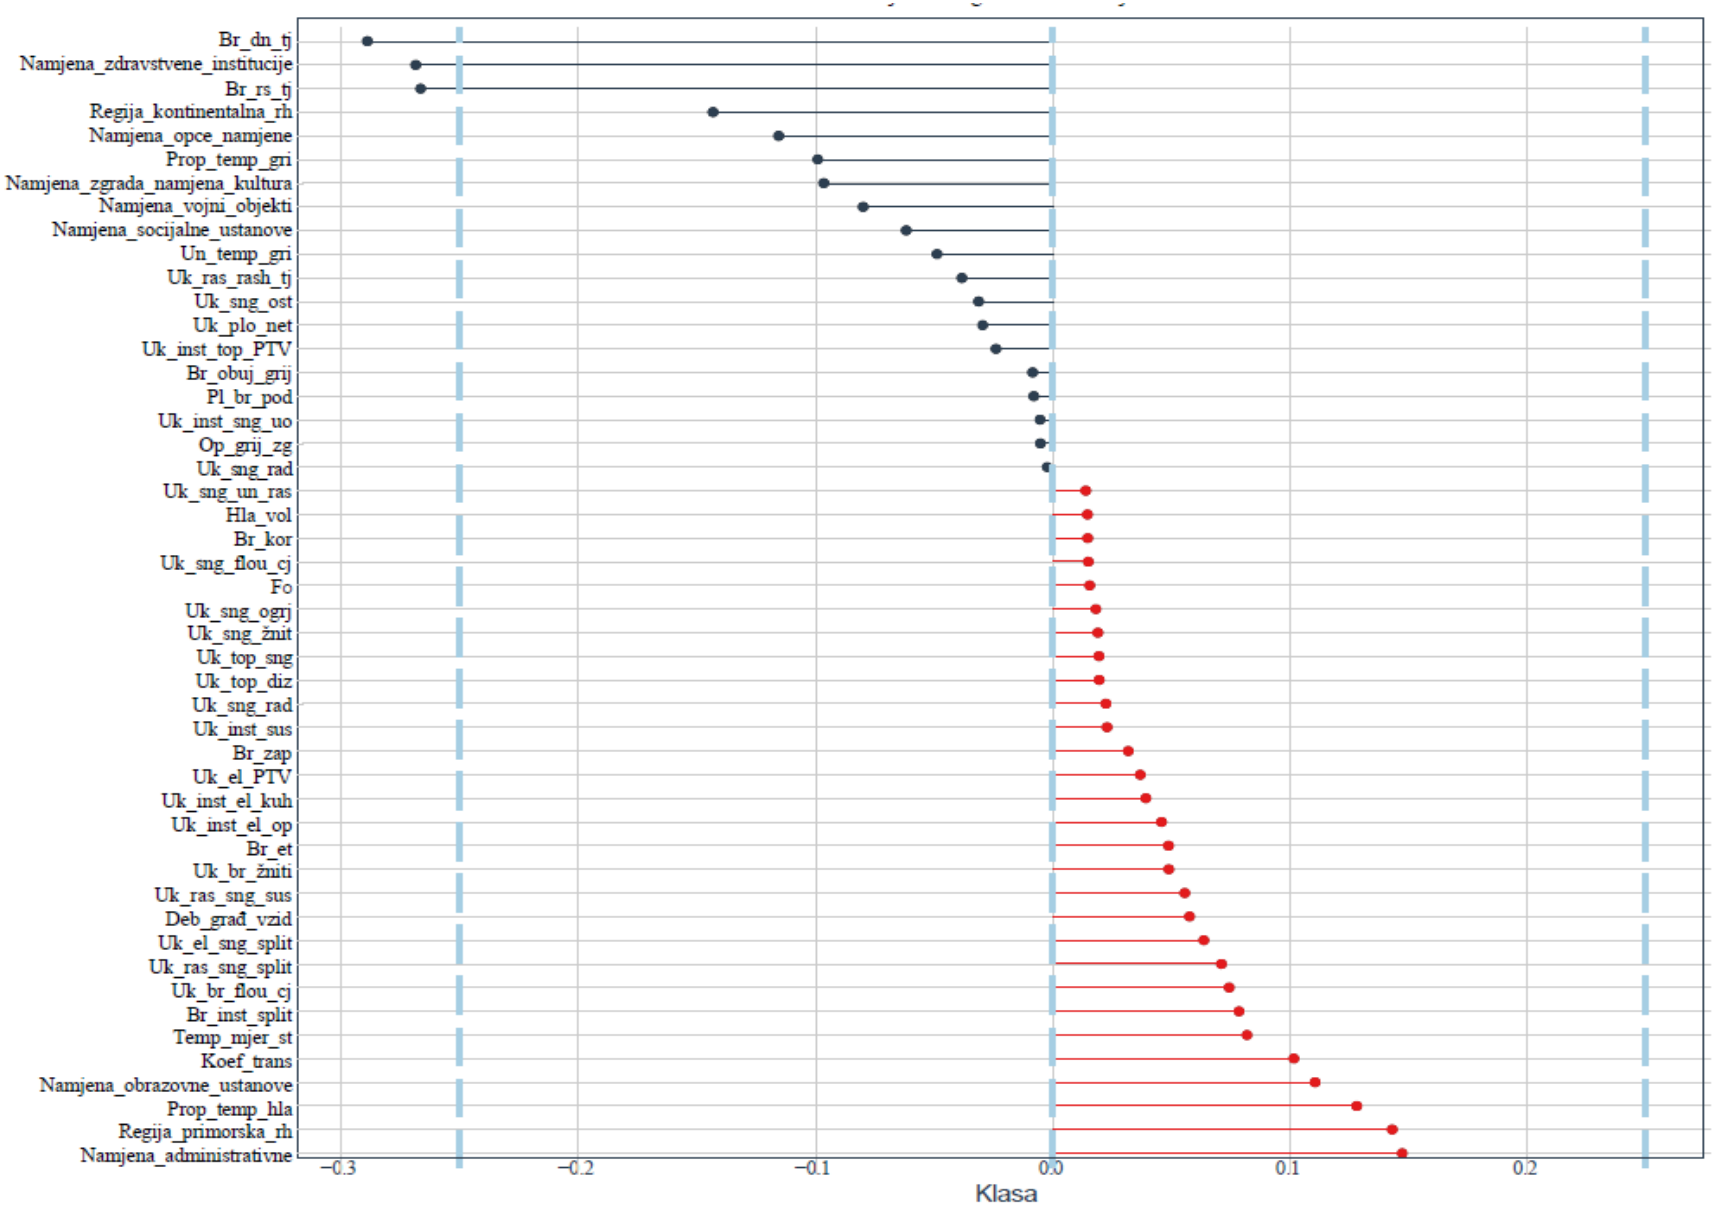

Izvor: Izrada autora

Na slici 29 vidljivo je da je 29 varijabli značajno za model, odnosno imaju značajan utjecaj na ciljnu varijablu *Klasa*, dok 19 varijabli nema značajan utjecaj. Varijable koje su se pokazale značajnima za model su: Namjena zgrade *(Namjena_administrativne),* Regija *(Regija_primorska_rh),* Unutarnja projektna temperatura u sezoni hlađenja *[°C](Prop_temp_hla),* Namjena *(Namjena_obrazovne ustanove),* Izračunati koef. transmis. topl. gubitka po jed. oplošja grij. dijela zgrade H'tr,iz [W/m²K] *(Koef_trans),* Temperatura na meteorološkoj stanici *(Temp_mj_st),* Broj instaliranih split sustava *(Br_inst_split),* Ukupni broj svjetiljki s fluokompaktnim žaruljama *(Uk_br_flou_cj),* Ukupna instalirana rashladna snaga split sustava *[kW](Uk_ras_sng_split),* Ukupna instalirana električna snaga split sustava *[kW](Uk_el_sng_split),* Debljina građevnog dijela [cm] – vanjski zid *(Deb_građ_vzid),* Ukupna instalirana rashladna snaga sustava [kW] *(Uk_ras_sng_sus),* Ukupni broj svjetiljki sa žaruljama sa žarnom niti (*Uk_br_žniti*), Broj katova *(Br_et),* Ukupna instalirana električna snaga ostalih potrošača [kW] *(Uk_inst_el_op),* Ukupna instalirana električna snaga kuhinjske opreme[kW]*(Uk_inst_el_kuh),* Ukupna instalirana električna snaga sustava PTV [kW]*(Uk_el_PTV),* Broj zaposlenih *(Br_zap),* Ukupna instalirana snaga ostalih sustava [kW]*(Uk_inst_sus),* Ukupan broj ogrjevnih tijela – radijatora *(Uk_sng_rad),* Ukupna instalirana toplinska snaga dizalice topline [kW]*(Uk_top_diz),* Ukupna instalirana snaga žarulja sa žarnom niti [kW] *(Uk_sng_žnit),* Ukupna instalirana toplinska snaga ogrjevnih tijela [kW]*(Uk_sng_ogrj),* Faktor oblika zgrade *(F_O),* Ukupna instalirana snaga fluorescentnih cijevi s elektromag.prigušnicom [kW]*(Uk_sng_flou_cj),* Broj korisnika *(Br_kor),* Hlađena površina *(Hlad_vol)* te Ukupna instalirana snaga unutarnje rasvjete [kW]*(Uk_sng_un_ras).*

Najmanji utjecaj na ciljnu varijablu *Klasa* pokazale su varijable*:* Broj radnih dana u tjednu *(Br_dn_tj),* Namjena zgrade *(Namjena_zdravstvene institucije),* Broj radnih sati u danu *(Br_rs_dn),* Regija *(kontinentalna_rh),* Namjena *(Namjena_opće_namjene),* Propisana interna temperatura u sezoni grijanja *(Prop_temp_gri),* Namjena *(Namjena_zgrada namjena_kulturi),* Namjena *(Namjena_vojni_objekti),* Namjena *(Namjena_socijalne_ustanove),* Unutarnja projektna temperatura u sezoni grijanja [°C] *(Un_temp_gri),* Ukupna instalirana rashladna snaga rashladnih tijela [kW] *(Uk_ras_rash),* Ukupno instalirana snaga ostalih ogrjevnih tijela [kW] *(Uk_sng_ost),* Ukupna ploština neto podne površine grijanog dijela zgrade *(Uk_plo_net),* Ukupna instalirana toplinska snaga sustava PTV [kW] (*Uk_inst_top_PTV*), Bruto obujam grijanog dijela zgrade kojem je oplošje A [m³] *(Br_obuj_grij),* Ploština bruto podne površine zgrade [m²] *(Pl_br_pod),* Ukupna instalirana električna snaga uredske opreme [kW] *(Uk_inst_sng_uo),* Oplošje grijanog dijela zgrade A [m²] *(Op_grij_zg),* Ukupno instalirana snaga

ogrjevnih tijela - radijatora [kW] *(Uk_sng_rad)* te Ukupna instalirana snaga unutarnje rasvjete [kW] *(Uk_sng_un_ras).*

Osim prikaza varijabli na model na globalnoj razini, tj. osjetljivosti modela na pojedinu varijablu, istražila se i važnost varijabli na lokalnoj razini predviđanja pojedine klase u modelu. Lokalna značajnost varijabli napravljena je za sve zgrade javnog sektora koje se nalaze u uzorku za testiranje, odnosno za 439 zgrade. Za utvrđivanje lokalne značajnosti korišten je paket LIME u alatu R.

LIME (engl. *local interpretable model-agnostic explanations*) predstavlja metodu za objašnjenje pojedinačnih predviđanja u modelu i na taj način omogućuje točnije objašnjenje modela u odnosu na globalnu značajnost (Ribeiro i suradnici, 2016). Zhang i suradnici (2018) navode da riječ agnostički u nazivu LIME implicira mogućnost pružanja uvida u proces koji "nije poznat ili ne može biti poznat", što je posebno važno za neuronske mreže. LIME metoda prikladna je i za klasifikacijske i regresijske modele (Zhang i suradnici, 2018).

U nastavku prikazana je lokalna značajnost varijabli za prva dva slučaja koji predstavljaju prve dvije zgrade javnog sektora u uzorku za testiranje (slika 30). Na grafičkom prikazu plava linija (*Podrška)* označava da prisutnost pojedine varijable povećava vjerojatnost da će određeni slučaj nalaziti u određenoj klasi. Crvena linija (*Kontraindikacija*) označava suprotno, ukazuje da prisutnost te varijable smanjuje vjerojatnost da će slučaj biti iz te određene klase. Nadalje, LIME za svaki pojedini slučaj prikazuje vjerojatnost pripadnosti (engl. *Probability*) te koeficijent objašnjenja (engl. *Explanation Fit*). Vjerojatnost ukazuje na postotak pripadnosti pojedinoj klasi, dok je koeficijent objašnjenja ekvivalentan R^2 i govori koliko je LIME uspješan u objašnjenju modela.

Slika 30 Značajnost varijabli na lokalnoj razini

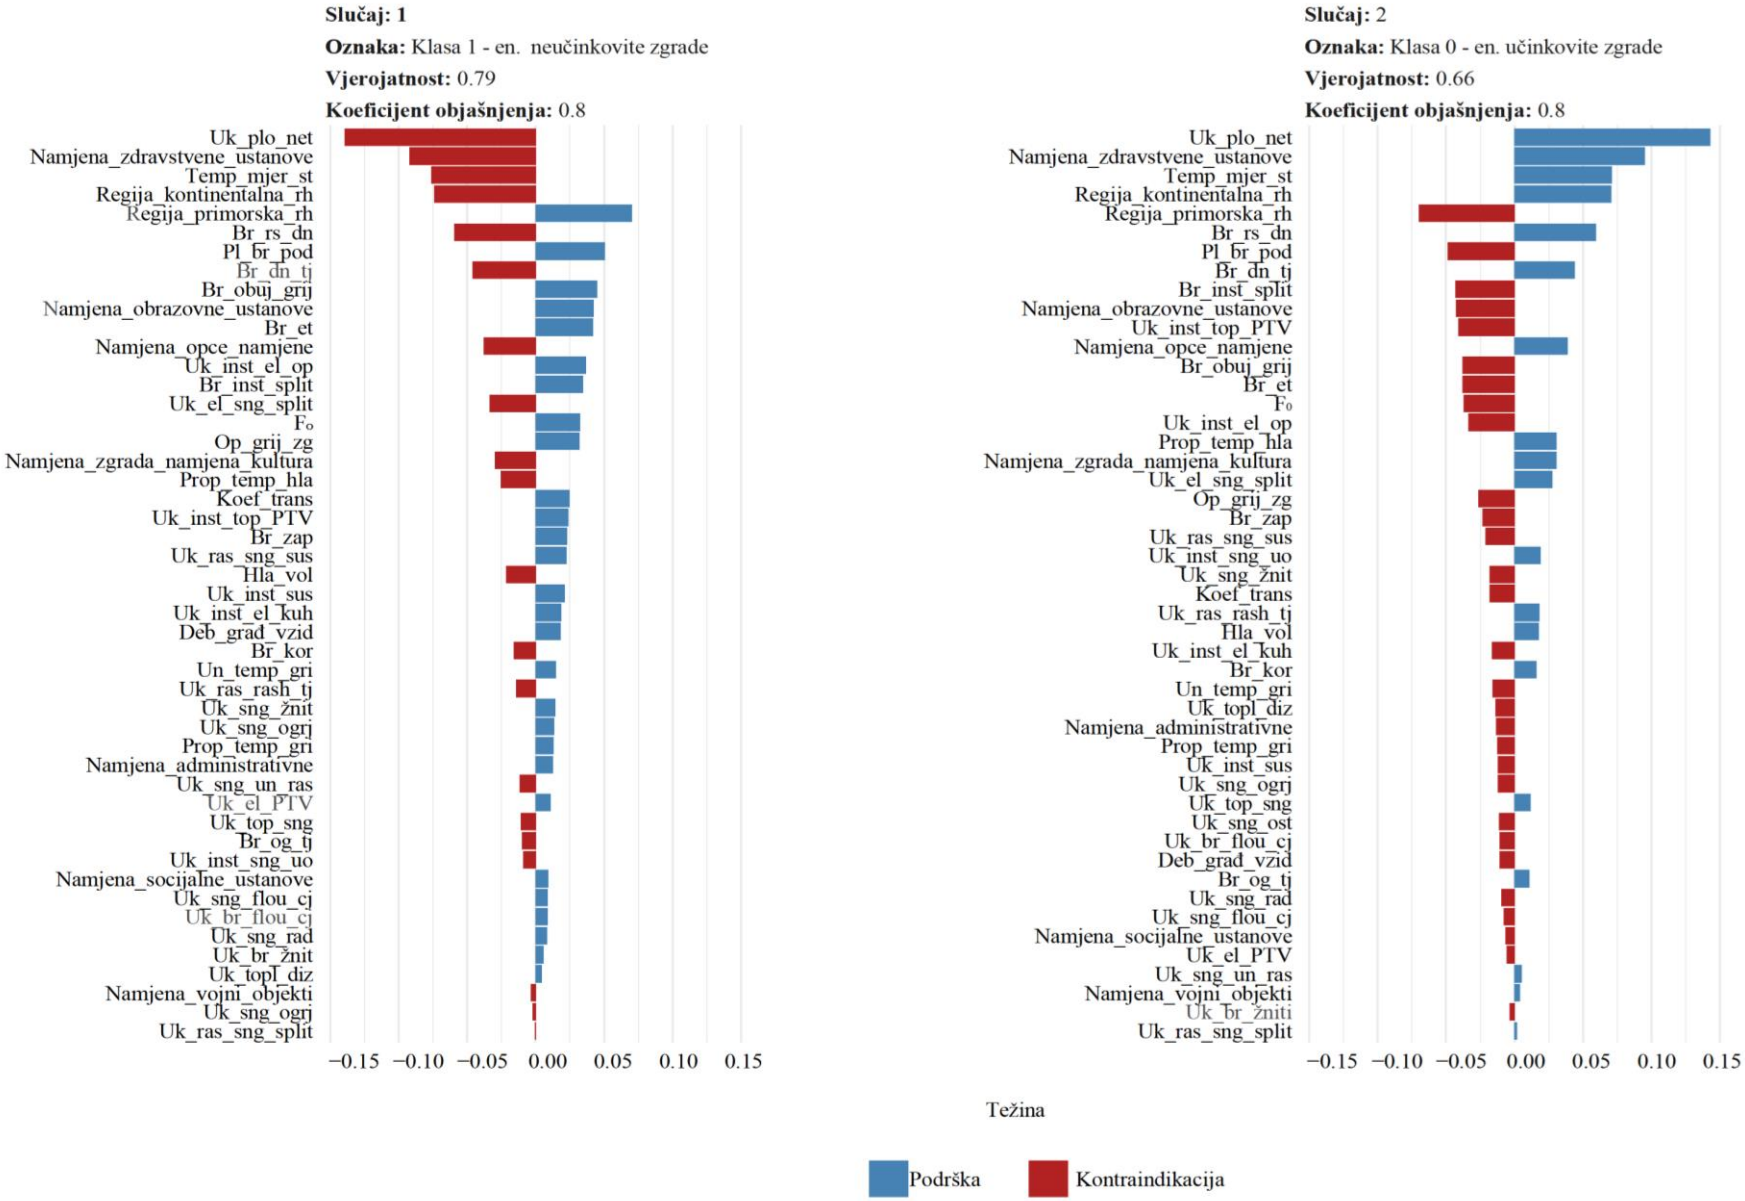

Izvor: Izrada autora

Iz slike 30 vidljivo je da je **slučaj broj 1** (*prva zgrada javnog sektora u uzorku za testiranje* (engl. *hold-out*)) model klasificirao kao energetski neučinkovitu zgradu javnog sektora te varijable označene plavom linijom povećavaju vjerojatnost da *Slučaj 1* zaista pripada klasi energetski neučinkovitih zgrada, dok varijable označene crvenom linijom smanjuju vjerojatnost pripadnosti klasi energetski neučinkovitih zgrada. Koeficijent objašnjenja u *Slučaju 1* iznosi 0,80, a vjerojatnost pripadnosti *Slučaja 1* klasi energetski neučinkovitih zgrada je 79 %. Kao najznačajnije varijable za klasificiranje *Slučaja 1* u energetski neučinkovite zgrade su Regija – primorska Hrvatska *(Regija_primorska_rh),* Bruto obujam grijanog dijela zgrade kojem je oplošje A [m³]*(Br_obuj_grij),* Ploština bruto podne površine zgrade [m²] *(Pl_br_pod), Broj instaliranih split sustava,* Broj katova *(Br_et),* Zgrade s namjenom u obrazovanju *(Namjena_obrazovne_ustanove),* Ukupna instalirana električna snaga ostalih potrošača [kW] *(Uk_inst_el_op),* Broj instaliranih split sustava *(Br_inst_split*), Faktor oblika (F_o), Oplošje grijanog dijela zgrade A [m²] *(Op_grij_zg),* Koeficijent transmisijskog toplinskog gubitka po jedinici oplošja grijanog dijela zgrade H'tr,iz [W/m²K] *(Koef_trans*), Ukupna instalirana toplinska snaga sustava PTV [kW] *(Uk_inst_top_PTV)* te Broj zaposlenih *(Br_zap).* Najveći utjecaj na smanjenje vjerojatnosti da će *Slučaj 1* pripasti klasi energetski neučinkovitih zgrada imaju varijable: Ukupna ploština neto podne površine grijanog dijela zgrade *(Uk_plo_net),* Namjena zgrade – zdravstvena ustanova (*Namjena_zdravstvene_ustanove*), Temperatura na meteorološkoj stanici *(Temp_mjer_sta),* Regija – kontinentalna Hrvatska (*Regija_kontinentalna_rh),* Broj radnih sati u danu *(Br_rs_dn)* te Broj radnih dana u tjednu *(Br_rd_tj).*

Slučaj broj 2 (*druga po redu zgrada javnog sektora u uzorku za testiranje)* model je svrstao u klasu energetski učinkovitih zgrada s vjerojatnošću od 66 % i s koeficijentom determinacije od 0,80. Kao najznačajnije varijable u *Slučaju broj 2* istaknule su se: Ukupna ploština neto podne površine grijanog dijela zgrade *(Uk_plo_net),* Namjena zgrade - zdravstvo (*Namjena_zdravstvene_ustanove*), Regija - kontinentalna Hrvatska *(Regija_kontinentalna_rh),* Temperatura na meteorološkoj stanici *(Temp_mjer_sta)* te Broj radnih sati u radnom danu *(Br_rs_dn).* Varijable koje imaju najveći utjecaj na smanjenje vjerojatnosti da će *Slučaj 2* pripasti klasi energetski učinkovitih zgrada su: Ploština bruto podne površine zgrade [m²] *(Pl_br_pod),* Regija – primorska Hrvatska te Broj instaliranih split sustava *(Br_inst_split).* Analiza značajnosti varijabli na lokalnoj razini može pridonijeti boljoj alokaciji financijskih sredstava i planiranju ulaganja u energetsku obnovu zgrade. Modelom je omogućeno da se za svaku zgradu javnog sektora dobiju i analiziraju najznačajniji prediktori.

5. RASPRAVA

U ovom poglavlju analizirat će se dobiveni rezultati empirijskog dijela istraživanja, ali i ograničenja provedenog istraživanja. Proces obrade i pripreme podataka ukazao je na mnoge probleme ISGE sustava, a time i na ograničenja provedenog istraživanja. Brojne zgrade javnog sektora isključene su iz uzorka zbog prevelikog broja nedostajućih vrijednosti te vrijednosti koje su iznad mogućih intervala. Algoritam obrade i čišćenja podataka o građevinskim i uporabnim karakteristikama zgrada korišten je za zamjenu nedostajućih vrijednosti s obzirom na to da se radi o specifičnim podacima te neke vrijednosti nije moguće zamijeniti prosječnim vrijednostima ili nekom drugom metodom imputacije. Nakon pripreme podataka provedeno je istraživanje u dva smjera; istraživanje fenomena odstupanja u potrošnji energije u zgradama te izradi modela strojnog učenja za klasifikaciju zgrada javnog sektora prema njihovoj stvarnoj potrošnji energije.

U radu predstavljene su tri glavne hipoteze dobivene na temelju postavljenih istraživačkih pitanja. Prva hipoteza u radu glasila je:

Postoje odstupanja između stvarne potrošnje energije i proračunske potrošnje energije iskazane na energetskim certifikatima zgrada javnog sektora

Iako ukupan uzorak broji 2.192 zgrade javnog sektora, istraživanje o odstupanju u potrošnji energije provedeno je na 579 zgrada javnog sektora za koje je dostupan podatak o proračunskoj potrošnji energije za potrebe grijanja nestambenog prostora, odnosno na onim zgradama za koje je dostupan podatak o energetskoj učinkovitosti iskazan na energetskom certifikatu. Postojanje odstupanja u potrošnji ustanovljeno je za 353 zgrade javnog sektora. Kod 60 % promatranih zgrada utvrđena je veća stvarna potrošnja energije za potrebe grijanja nego što je iskazano podacima navedenim energetskim certifikatom.

Godišnja potrebna toplinska energija, odnosno proračunska potrošnja energije, daje uvid u očekivanu energetsku učinkovitost zgrade i putokaz je za upravljanje potrošnjom energije, ali i za donošenje odluka o ulaganju u energetsku učinkovitost i obnovu zgrada javnog sektora. Međutim, ako je temeljem proračunskih vrijednosti zgradi dodijeljen energetski razred B, a njezina stvarna potrošnja energije znatno je viša od potrošnje za energetski razred B, ili ako je energetski razred zgrade D, a stvarna potrošnja te iste zgrade znatno je niža od toga, nameće se pitanje o točnosti postojećih modela za izračun proračunske potrošnje energije u zgradama, odnosno pokazuje li dodijeljeni energetski razred zaista „pravo“ stanje u potrošnji energije te

može li kao takav biti valjana podloga za donošenje planova za upravljanje energetskom učinkovitosti u zgradama.

Fenomen odstupanja u potrošnji energije koji je u literaturi poznat pod nazivom „*odstupanje u potrošnji energije*“ istraživali su brojni autori. Međutim, termin odstupanja u potrošnji energije vrlo je širok, ovisi o gledištu istraživača, kao i sama magnituda odstupanja što je i prikazano u ranijim poglavljima. U Hrvatskoj nedostaje više istraživanja ovog problema, osim kvantitativne analize nedostaju i kvalitativna istraživanja kojima bi se istražilo koji je dubinski uzrok takvog odstupanja. Posebno jer su pojedini istraživači došli do zaključka kako je često veća potrošnja energije u energetski učinkovitim zgradama, dok je manja potrošnja energije u energetski lošijim zgradama. Obje situacije dovode do novih fenomena, kao što je Jevonsov paradoks u prvom slučaju ili energetsko siromaštvo i susprezanje od korištenja energije u drugom slučaju. Pregledom literature utvrđeno je da uzrok odstupanja može biti u bilo kojem životnom ciklusu zgrade iz različitih razloga: u fazi projektiranja zgrade (ograničenja, netočnosti i pretpostavke u modelima koji se koriste za predviđanje energetske učinkovitosti, kompleksnosti projekta); fazi izgradnje (*loša kvaliteta izrada i razlika između pretpostavljenih i korištenih materijala, komponenti i sustava, odstupanja od projekta i sl.*) te u fazi uporabe zgrade (*loše upravljanje energijom u zgradama i/ili nepoklapanje između pretpostavljene i stvarne upotrebe zgrade, utjecaj korisnika*).

Odstupanje u potrošnji između stvarno potrošene količine energije i proračunske količine energije potvrđeno je jednostranim t test za testiranje jednakosti očekivanja dvaju zavisnih uzoraka o stvarnoj i proračunskoj potrošnji energije, uz alternativnu hipotezu da je razlika među očekivanjima veća od nule u korist stvarne potrošnje. Pritom je korištena razina značajnosti $\alpha=0,05$.

Hipoteze su postavljene na sljedeći način:

H0: Ne postoji značajna razlika u odstupanju stvarne potrošnje energije i procijenjene potrošnje prema energetskim certifikatima zgrada javnog sektora.

H1: Postoji značajna razlika između stvarne potrošnje energije i procijenjene potrošnje prema energetskim certifikatima zgrada javnog sektora

Dobivena p vrijednost iznosi $5,934 * 10^{-6}$ te se na razini značajnosti 0,05 odbacuje H0. Provedeno istraživanje na danom uzorku ukazuje na to da je stvarna potrošnja energije za

potrebe grijanja u zgradama javnog sektora veća od proračunske potrošnje energije za potrebe grijanja. S obzirom na to da je utvrđeno statistički značajno odstupanje u potrošnji energije između stvarne i proračunske potrošnje energije za potrebe grijanja napravila se detaljna analiza tih zgrada javnog sektora. Utvrđeno je kako je prosječna stvarna potrošnja energije u tim zgradama javnog sektora iznosila 162,30 kWh/m², odnosno potrošnja je ekvivalentna energetskom razredu E, dok je prosjek proračunske potrošnje energije za potrebe grijanja izražene na energetskim certifikatima u tom podskupu zgrada javnog sektora iznosio 91,40 kWh/m² što bi bilo ekvivalentno energetskom razredu C. Ti podaci sugeriraju da promatrane zgrade neučinkovito troše energiju. Najveći broj zgrada javnog sektora kod kojih je utvrđeno odstupanje pripada obrazovnom sektoru (52 %) dok ostatak čine uredske zgrade (28 %), zdravstvene institucije (10 %), zgrade socijalne namjene (6 %) te zgrade namijenjene kulturi s najmanjim udjelom (2 %).

Važnost upravljanja odstupanjem u potrošnji energije ogleda se i u troškovima energije. O troškovima energije u javnim zgradama najčešće se diskutira prilikom rasta cijena energenata upravo zbog nemogućnosti podmirivanja istih. Unatoč tome, problem potrošnje energije često je marginaliziran u zgradama javnog sektora, a do toga dolazi jer ne postoje pojedinačne odgovornosti i stoga je nužno tom problemu pristupiti korištenjem poduzetničkih principa. U prethodnim poglavljima navedeni su općeniti problemi energetske učinkovitosti, ali i oni specifični za javni sektor kao što su: komplicirani procesi donošenja odluka o ulaganju u energetsku učinkovitost, ograničen budžet, javna nabava i sl. Inovativno i proaktivno pristupanje ovom problemu i veća odgovornost menadžmenta zgrada javnog sektora te edukacija i proaktivno djelovanje svih zaposlenika i korisnika u zgradama javnog sektora zasigurno bi pridonijelo povećanju energetske učinkovitosti, a time bi se smanjila i magnituda odstupanja.

Istraživanje odstupanja u potrošnji energije provedeno u ovoj doktorskoj disertaciji konzistentno je s istraživanjima autora predstavljenim u prethodnim poglavljima koje iznose od 30 % do 40 %, međutim pojedini autori identificirali su i veća odstupanja. U ovom je istraživanju magnituda odstupanja između 40 % i 50 % ovisno o namjeni zgrade. U zgradama obrazovne namjene utvrđeno je odstupanje od 43,45 % u odnosu na proračunske vrijednosti potrošnje energije, kod uredskih zgrada ono iznosi 42,99 %, zdravstvene institucije bilježe odstupanje od 47,16 % te slično odstupanje zabilježeno je u zgradama socijalne namjene (47,56 %).

Kod zgrada kulturne namjene odstupanje je najviše i iznosi 61,27 %. No, s obzirom da se u uzorku nalazi sedam zgrada čija je namjena u kulturi dobiveno odstupanje treba dodatno istražiti na većem broju zgrada kulturne namjene.

Zajedničke karakteristike zgrada javnog sektora kod kojih je utvrđeno odstupanje u potrošnji su: starost (najviše njih je izgrađeno od 1945. do 1980. godine), smještene su u kontinentalnoj Hrvatskoj i stvarna potrošnja energije ekvivalentna je energetskom razredu D ili E.

Odstupanje u potrošnji može se promatrati i u drugom smjeru, odnosno kada je stvarna potrošnja energije niža od proračunska potrošnja energije za potrebe grijanja. Takva situacija je zabilježena i u ovom istraživanju kod 226 zgrade javnog sektora. Prosječna stvarna potrošnja energije u takvim zgradama javnog sektora iznosila je 162,30 kWh/m² što je ekvivalentno energetskom razredu E dok je prosjek proračunske potrošnje energije za potrebe grijanja iznosio 91,40 kWh/m² što je ekvivalentno energetskom razredu C. U ovom slučaju magnituda odstupanja više varira među skupinama zgrada javnog sektora, kod zgrada s namjenom u obrazovanju odstupanje u korist stvarne potrošnje energije je 64,87 %. U uredskim zgradama ono iznosi 25,55 %, a kod zdravstvenih institucija zabilježeno odstupanje je 43,89 %. Zgrade socijalne namjene bilježe najveću magnitudu odstupanja koja iznosi 291,04 %, a uzrok tome može biti i mali broj zgrada (4 zgrade) dok zgrade namijenjene kulturi bilježe odstupanje od 42,07 %.

U literaturi uglavnom je fokus na odstupanje u potrošnji energije koje je veće od predviđenih razina. No u prethodnim istraživanjima navedeno je i istraživanje Katića i suradnika (2021) koje potvrđuje odstupanje u zgradama obrazovne namjene gdje je stvarna potrošnja energije niža od proračunske potrošnje. Navedeni autori proveli su istraživanje u obrazovnim institucijama u BiH, a dobiveni rezultati odstupanja konzistentni su s dobivenim rezultatima u ovom istraživanju kada se promatraju zgrade obrazovne namjene.

S obzirom na postojanje odstupanja u potrošnji energije istražila se i točnost proračunskih vrijednosti iskazanih na energetskim certifikatima analiziranog poduzorka zgrada javnog sektora. Usporedba je napravljena na slijedeći način. Uspoređen je energetski razred za 579 zgrada javnog sektora koji je iskazan na energetskom certifikatu te je uspoređen sa stvarno potrošenom energijom za potrebe zagrijavanja nestambenih površina. Energetski razred i stvarno potrošena energija u zgradama javnog sektora radi lakšeg tumačenja stavljeni su u odnos u matrici konfuzije. Putem matrice konfuzije izračunata je ukupna stopa točnosti

klasifikacije za postojeće metode energetskog certificiranja zgrada. Matrica konfuzije prikazana je u nastavku (tablica 35).

Tablica 35 Matrica konfuzije - proračunska i stvarna potrošnja energije za potrebe grijanja

	Stvarna potrošnja toplinske energije za potrebe grijanja						**Ukupno**
Proračunska potrošnja za potrebe grijanja iskazana na energetskom certifikatu	**B**	**C**	**D**	**E**	**F**	**G**	
A	5	11	7	9	3	1	36
B	**10**	26	11	9	2	1	59
C	16	**57**	50	18	10	5	156
D	12	23	**56**	31	17	10	149
E	4	14	23	**35**	13	14	103
F	2	3	13	10	**3**	3	34
G	3	3	8	5	9	**14**	42
Ukupno	52	137	168	117	57	48	**579**

Izvor: Izrada autora

U stupcima prikazane su stvarne vrijednosti potrošene energije za potrebe zagrijavanja nestambene površine, dok su u redcima prikazane proračunske vrijednosti. Ispravno svrstani slučajevi nalaze se u dijagonali, a sve izvan dijagonale smatra se pogrešnom klasifikacijom. Na temelju prikazane matrice konfuzije izračunata je ukupna stopa točnosti klasifikacije postojećeg modela za energetsko certificiranje i ona iznosi 30,22 %. Drugim riječima, od ukupno 579 zgrada javnog sektora proračunski model ispravno je klasificirao 175 zgrada, odnosno „pogodio“ njihovu stvarnu potrošnju energije. U analiziranom uzorku niti jedna zgrada ne pripada energetskom razredu A, stopa točnosti klasifikacije za energetski razred B iznosi 19,23 %, energetski razred C 41,60 %, energetski razred D 33,33 %, energetski razred E 29,91 %, energetski razred E 5,26 % te energetski razred F 29,16 %.

Energetski certifikat podloga je za donošenje odluka o ulaganju u energetsku učinkovitost i odabir zgrada koje će biti uključene u programe energetske obnove. Predstavlja prvi korak koji su korisnici zgrada javnog sektora obvezni ishoditi prilikom prijave na natječaje za energetsku obnovu javnih zgrada. Prethodno analizirane vrijednosti govore o potrošnji energije za potrebe grijanja. Međutim, na stvarnu potrošnju energije u zgradama utječu brojni čimbenici te je u

Odluci o upravljanju programom energetske obnove u razdoblju 2016. - 2020. jasno naznačeno da je potrebno pronaći model koji će uključivati stvarnu potrošnju energije.

Promišljanja kako poboljšati postojeću proceduru energetske obnove zgrada javnog sektora i potaknuti inovativno i proaktivno djelovanje provoditelja programa energetske obnove javnog sektora dovelo je do ideje za izradu modela strojnog učenja koji bi služio kao potpora odlučivanju prilikom prijave i pokretanja programa energetske obnove neučinkovitih zgrada javnog sektora. Korisnici zgrada javnog sektora dužni su unositi podatke o zgradama javnog sektora u ISGE sustav i upravo taj sustav činio se kao izvrstan alat u koji bi se takav model mogao implementirati. U ISGE sustav korisnici unose podatke i o energetskom certifikatu. No kako je iz prethodnog navedeno, od 2192 zgrade javnog sektora samo za njih 579 poznat je energetski razred. Zbog toga zgrade za koje energetski razred nije poznat nalaze se u statusu quo. Ne zna se jesu li energetski učinkovite ili ne dok se ne pokrene procedura energetske obnove, ako korisnik uopće krene u taj proces.

Stoga je osnovna ideja bila izraditi model strojnog učenja koji će na temelju postojećih podataka dostupnih u ISGE sustavu moći klasificirati zgrade u energetski „dobre“ i energetski „loše“ zgrade. Cilj je modela što bolje identificirati energetski loše zgrade, a sve s namjerom proaktivnijeg djelovanja javnog sektora i poboljšanja postojećeg procesa obnove zgrada javnog sektora. Cilj je pokrenuti zgrade javnog sektora iz statusa quo te identificirati energetski neučinkovite zgrade i prioritetno ih uključiti u programe energetske obnove. Iz toga je proizašla druga hipoteza ovog rada koja glasi:

Model za procjenu potrošnje energije temeljen na strojnom učenju smanjit će jaz u predviđanju i dati točnije procjene potrošnje energije od postojećih metoda energetskog certificiranja.

Model strojnog učenja za klasifikaciju zgrada javnog sektora obuhvatniji je od postojećih modela energetskog certificiranje jer uključuje znatno više podataka uključujući i podatke o načinu korištenja zgrade te je usmjeren na stvarnu potrošnju energije. Podaci korišteni u izradi modela mogu se podijeliti u nekoliko skupina: *podaci o tehničkim i građevinskim karakteristikama, meteorološki podaci* te *podaci o načinu i režimu korištenja zgrade*. Priprema podataka i definiranje ciljne varijable bili su prvi korak u izradi modela. Uzorak čine 881 zgrada javnog sektora koje su okarakterizirane kao zgrade s dobrim energetskim svojstvima te 1311 zgrada javnog sektora koje su okarakterizirane kao energetski loše zgrade. Metoda strojnog

učenja na kojem je model baziran su umjetne neuronske mreže. S ciljem dobivanja što boljih rezultata napravljena su tri modela koji se razlikuju ovisno o broju varijabli u ulaznom prostoru.

Nakon pripreme podataka 69 varijabli nalazilo su u uzorku, a s obzirom na njihov značajan broj pristupilo se selekciji varijabli temeljem dvije različite skupine metoda za selekciju varijabli. Filter metoda u kojoj je korelacija korištena za kontinuirani tip varijabli te $\chi 2$ za kategorijalni tip varijabli; druga korištena metoda je metoda omotača gdje su temeljem algoritma Boruta selektirane varijable. Filter metodom identificirano je 25 najznačajnijih varijabli, dok su algoritmom Boruta izdvojene 41 varijable. Kao značajne varijable u obje metode pokazale su se: *Broj radnih dana, Broj radnih sati, Vanjska temperatura, Koeficijent transmisijskog toplinskog gubitka po jedinici oplošja grijanog dijela, Propisana interna temperatura u sezoni grijanja i hlađenja, Ukupan broj ogrjevnih tijela – radijatora, Ukupno instalirana snaga ogrjevnih tijela - radijatora [kW], Ukupna toplinska snaga [kW], Ukupna instalirana rashladna snaga split sustava [kW], Ukupna instalirana električna snaga split sustava [kW], Ukupna instalirana rashladna snaga sustava [kW], Ukupna instalirana toplinska snaga sustava PTV [kW], Ukupna instalirana električna snaga sustava PTV [kW], Ukupna instalirana snaga žarulja sa žarnom niti [kW], Ukupni broj svjetiljki s fluorescentnim cijevima s elektromag. prigušnicom, Ukupna instalirana električna snaga uredske opreme [kW], Ukupna instalirana električna snaga kuhinjske opreme [kW], Ukupna instalirana električna snaga ostalih potrošača [kW], Ploština građevnog dijela [m²], Regija* te *Namjena zgrade*.

Iz prikazanih varijabli može se utvrditi da su meteorološki podaci, podaci o korištenju i instaliranim sustavima značajni prediktori.

S obzirom na to da umjetne neuronske mreže imaju tri faze rada, uzorak je podijeljen na tri dijela. Faza treniranja obuhvatila je 80 % uzorka, od toga je 15 % uzorka korišteno za unakrsnu validaciju, dok je 20 % uzorka ostavljeno za testiranje modela, odnosno 439 zgrada javnog sektora. Za svaki model napravljene su četiri topologije umjetnih neuronskih mreža: od jednog do četiri skrivena sloja s testiranim različitim brojem skrivenih neurona (1 do 130) u svakom skrivenom sloju. Testirani su različiti optimizacijski algoritmi (*Adam, Nadam, Rmsprop, SGD*) te različite aktivacijske funkcije kao što su: *tvrda sigmoidna funkcija, sigmoidna funkcija, tangens -hiperbolična funkcija i ReLU funkcija*.

Prvi model, odnosno *Model 1,* uključivao je svih 69 varijabli u ulaznom prostoru, drugi model - *Model 2* u ulaznom prostoru sadržavao je varijable dobivene temeljem filter metode za selekciju varijabli dok je treći model - *Model 3* u ulaznom prostoru sadržavao varijable dobivene metodom omotača (algoritam Boruta). Sva analiza i modeliranje rađeno je u alatu R.

Za sve modele izračunate su slijedeće metrike: stopa točnosti klasifikacije, AUC, preciznost, odaziv te F1 ocjena. Prilikom odabira optimalnog modela vodilo se ciljem ovog rada, odnosno odabran je model koji je pokazao najbolju uspješnost u identifikaciji energetski loših zgrada, a da pri tome stopa točnosti klasifikacije energetski učinkovitih zgrada nije manja od 60 %. Ukupna stopa točnosti klasifikacije nije se uzimala u obzir kao isključivo mjerilo uspješnosti modela zbog disbalansa u uzorku, odnosno zastupljenosti klasa.

Na temelju rezultata metrika za ocjenu uspješnosti modela za implementaciju je *Model 3* čija je arhitektura 48-20-2. Ova arhitektura govori da se u ulaznom sloju nalazi 48 neurona, 20 neurona u skrivenom sloju te 2 neurona u izlaznom sloju.

Najvažnije mjerilo evaluacije u ovom modelu bila je stopa točnosti klasifikacije za energetski neučinkovite zgrade javnog sektora koja je iznosila 76,7 %. To se potvrđuje i pokazateljem odaziva (engl. *Recall*) koji pokazuje koliko je stvarno energetski neučinkovitih zgrada model zaista identificirao kao energetski neučinkovite zgrade. Pokazatelj odaziva iznosi 76,7 %. Pokazatelj preciznosti ukazuje na sposobnost modela da kada za pojedinu zgradu predvidi da će biti energetski učinkovita, ona zaista i jest energetski učinkovita. Pokazatelj preciznosti iznosi 75 %. Harmonijsku sredinu između pokazatelja preciznosti i odziva dobilo se F1 ocjenom te u dobivenom modelu ona iznosi 75,8 %. Pokazatelj vrijednosti površine ispod ROC krivulje također je jedan od važnih pokazatelja uspješnosti modela i u ovom radu iznosi 73,8 %.

U ovom istraživanju naglasak je na prepoznavanju energetski neučinkovitih zgrada i može se zaključiti da model pokazuje dobre performanse s obzirom na broj i kvalitetu podataka koje uključuje, ali i u usporedbi s uspješnošću postojećeg modela za energetsko certificiranje koji pokazuje vrlo nisku uspješnost klasifikacije. No kako bi se povećale performanse predloženog modela kao koraci u daljnjem istraživanju predlaže se daljnja redukcija varijabli, ali i primjena ostalih metoda strojnog učenja. U literaturi zanemariv se broj autora bavi klasifikacijom zgrada javnog sektora prema stvarnoj potrošnji energije, kod klasifikacije usmjerenost je na proračunske vrijednosti potrošnje dok su se za predviđanje stvarne potrošnje najčešće koristili

regresijski modeli. U području umjetnih neuronskih mreža velik uspjeh pokazuju duboke neuronske mreže. U ovoj doktorskoj disertaciji arhitektura dubokih neuronskih mreža bila je neznatno lošija u klasifikaciji zgrada javnog sektora prema stvarnoj potrošnji primarne energije.

Osnovna ideja iza ovog modela bila je nadogradnja sustava ISGE kako bi tijela zadužena za upravljanje energetskom učinkovitošću mogla bolje njome upravljati u javnom sektoru, identificirati zgrade s prevelikom potrošnjom energije, educirati korisnike takvih zgrada i uključiti ih u programe energetske obnove.

Jedan od ciljeva rada bio je i istražiti utjecaj građevinskih i konstrukcijskih, meteoroloških i uporabnih karakteristika na energetsku učinkovitost zgrada javnog sektora kako bi se ciljano moglo pristupiti poboljšanju energetski performansi pojedine zgrade. To je ujedno i treća hipoteza koja se postavila:

Na temelju dobivenog modela mogu se identificirati glavni prediktori potrošnje energije u zgradama javnog sektora koji će se koristiti u svrhu bolje alokacije financijskih resursa u energetsku obnovu zgrada i tako povećati učinkovitost javnog sektora.

Predloženi model strojnog učenja može služiti kao inteligentna potpora u donošenju odluka o energetskoj učinkovitosti jer daje uvid u energetske performanse zgrade, ali i najznačajnije prediktore energetske učinkovitosti. Najznačajniji prediktori predloženog modela, odnosno predloženi model, interpretiran je na dvije razine: globalnoj i lokalnoj. Najznačajniji prediktori na globalnoj razini mogu se podijeliti na **građevinske i konstrukcijske** (*Izračunati koef. transmis. topl. gubitka po jed. oplošja grij. dijela zgrade H'tr,iz [W/m²K], Ploština građevnog dijela [m²], Hlađena površina, Faktor oblika zgrade, Broj katova)*, **meteorološke** (*Unutarnja projektna temperatura u sezoni hlađenja [°C], Temperatura na meteorološkoj stanici)*, **uporabne** *(Broj korisnika, Broj zaposlenih, Namjena zgrade)*, **sustave instalirane u zgradi** *(Broj instaliranih split sustava, Ukupni broj svjetiljki s fluokompaktnim žaruljama, Ukupna instalirana rashladna snaga split sustava [kW], Ukupna instalirana električna snaga split sustava [kW], Ukupna instalirana rashladna snaga sustava [kW], Ukupni broj svjetiljki sa žaruljama sa žarnom niti, Ukupna instalirana električna snaga ostalih potrošača [kW], Ukupna instalirana električna snaga kuhinjske opreme [kW], Ukupna instalirana električna snaga sustava PTV [kW],Ukupna instalirana snaga ostalih sustava [kW], Ukupan broj ogrjevnih tijela – radijatora, Ukupna instalirana toplinska snaga dizalice topline [kW], Ukupna instalirana snaga žarulja sa žarnom niti [kW], Ukupna instalirana toplinska snaga*

ogrjevnih tijela [kW], Ukupna instalirana snaga fluokompaktnih žarulja [kW] te *Ukupna instalirana snaga unutarnje rasvjete [kW]).*

Proces energetske obnove može biti zahtjevan i skup. Međutim, malim izmjenama u načinu korištenja zgrada javnog sektora, promjenom ponašanja korisnika zgrada javnog sektora u kontekstu odgovornog trošenja energije, korištenjem učinkovitije rasvjete i sl. mogu se postići brojne uštede u potrošnji energije. Dobivene najznačajnije varijable konzistentne su istraživanjima ostalih autora predstavljenih u ovoj doktorskoj disertaciji.

S obzirom na to da su zgrade javnog sektora iznimno heterogene pristupilo se interpretaciji modela i na lokalnoj razini. Interpretacija na lokalnoj razini pruža dublji uvid u predloženi model. Pomoću metode LIME za svaku zgradu javnog sektora u uzorku za testiranje napravljena je analiza značajnosti kako bi se utvrdilo koji su prediktori najznačajniji u energetski neučinkovitim, a koji u energetski učinkovitim zgradama. Dobiveni koeficijent objašnjenja iznosi 80 % što ukazuje na to da LIME vrlo dobro objašnjava predloženi model.

Analiza značajnosti varijabli prikazana je za prve dvije zgrade javnog sektora u uzorku za testiranje: prvi slučaj (prva zgrada javnog sektora u uzorku za testiranje) model je klasificirao s vjerojatnošću od 79 % da pripada klasi energetski neučinkovitih zgrada i kao najznačajnije prediktore izdvojio: da se *radi o zgradama obrazovne namjene, da pripadaju primorskoj Hrvatskoj, Bruto obujam grijanog dijela zgrade kojem je oplošje A [m³], Ploština bruto podne površine zgrade [m²], Broj instaliranih split sustava, Broj katova, Oplošje grijanog dijela zgrade A [m²], Faktor oblika zgrade* te *Koeficijent transmisijskog toplinskog gubitka po jedinici oplošja grijanog dijela zgrade H'tr,iz [W/m²K]*. Najveći utjecaj na smanjenje vjerojatnosti da će *Slučaj 1* pripasti klasi energetski neučinkovitih zgrada ima varijabla *Ukupna ploština neto podne površine grijanog dijela zgrade,* ako je zgrada po namjeni *Zdravstvena institucija* te *Temperatura na meteorološkoj stanici*.

Kad se promotri druga po redu zgrada javnog sektora u uzorku za testiranje (Slučaj 2), vidljivo je da je model s vjerojatnošću od 66 % predvidio da ta zgrada javnog sektora pripada klasi energetski učinkovitih zgrada. Kao najznačajniji prediktori da će zgrada pripasti energetski učinkovitim zgradama identificirale su se slijedeće varijable: *Ukupna ploština neto podne površine grijanog dijela zgrade, Zgrade s namjenom u zdravstvu, Regija - kontinentalna Hrvatska, Temperatura na meteorološkoj stanici i Broj radnih sati u radnom danu*.

Na primjeru ova dva slučaja može se vidjeti da one varijable koje su među najznačajnijim prediktorima za pojedinu klasu često su najmanje značajni prediktori za drugu klasu. Na globalnoj i na lokalnoj razini kao značajne varijable za predviđanje energetski neučinkovitih zgrada pokazale su se varijable kojima se opisuje način korištenja zgrada te instalirani sustavi grijanja, rasvjete, oprema u zgradama. Način korištenja zgrada te efikasan režim rada i uporaba sustava i u literaturi nameću se kao jedan od razloga zbog kojih dolazi do odstupanja u potrošnji energije. Kako je i u prethodnim poglavljima navedeno, način na koji se može smanjiti odstupanje u potrošnji energije i učinkovitije upravljati energijom u zgradama javnog sektora jest kroz primjenu poduzetničkih principa, ponašanja i djelovanja.

Iz ove doktorske disertacije proizašle su i preporuke za povećanje učinkovitosti u zgradama javnog sektora. Preporuke se mogu podijeliti u preporuke za korisnike i menadžment zgrada javnog sektora, provoditelje procesa energetske obnove i upravljanja energijom te preporuke za integraciju modela u sustave pametnih zgrada i pametnih gradova.

Preporuke za provoditelje energetskih programa obnove i ostalih procesa vezanih uz energetsku učinkovitost:

- Osigurati vidljivost projekata energetske obnove i promicati sustavno upravljanje energijom u zgradama javnog sektora. Prikazati primjere dobre prakse upravljanja energijom u javnom sektoru. Intenzivirati promociju energetske učinkovitosti unutar javnog sektora, educirati djelatnike i menadžment javnog sektora o načinima učinkovitog upravljanja energijom. Organizirati aktivnosti s ciljem podizanja svijesti o problemu pretjerane i neučinkovite potrošnje energije. Osigurati informacijsko - komunikacijsku podršku u razvoju energetskog menadžmenata u javnom sektoru.

- Unaprijediti postojeću proceduru prijave u programe energetske obnove i odabira zgrada javnog sektora koje će u taj proces biti uključene. Postojeći model podržava status quo te dok se korisnik zgrade javnog sektora samostalno ne prijavi u proces energetske obnove brojne zgrade javnog sektora ostaju nezamijećene. Upravo je cilj predloženog modela za klasifikaciju zgrada javnog sektora prema stvarnoj primarnoj potrošnji energije izaći iz postojećeg okvira i omogućiti provoditeljima programa energetske obnove identifikaciju zgrada s najlošijim energetskim svojstvima te ih prioritetno uključiti u programe energetske obnove.

- Unaprijediti ISGE sustav kroz bolju kontrolu unosa podataka u sustav. Onemogućiti unos podataka koji su iznad mogućih intervala. Redovno informirati korisnike javnog sektora o potrebi i obvezi unosa podataka u sustava. Upoznavanje korisnika javnog sektora o mogućnostima ISGE sustava.

- Povezati postojeće sustave za upravljanje potrošnjom energije (baza ISGE, SMIV te Informacijski sustav energetski certifikata) te učinkovitije upravljati istima. Povezivanjem sustava omogućile bi se kvalitetnije informacije i bolja kontrola nad fondom zgrada javnog sektora u Republici Hrvatskoj.

Preporuke za menadžment i korisnike zgrada javnog sektora:

- Povećati svijest o potrošnji energije u zgradama javnog sektora. Educirati korisnike zgrada javnog sektora o konceptima i načinima upravljanja energetskom učinkovitošću. Podići razinu osobne odgovornosti o potrošnji energije u zgradama javnog sektora. Ukazati na osobne i društvene koristi koje mogu proizaći iz učinkovite potrošnje energije u zgradama javnog sektora.

- Uspostaviti energetski menadžment koji bi bio usmjeren na praćenje potrošnje i kontrolu troškova energije u zgradi. Imenovati tim zaposlenika koji će se aktivno baviti upravljanjem potrošnjom energije u zgradama i ostalim aktivnostima vezanim uz upravljanje energetskom učinkovitosti.

- Stvoriti poticajno okruženje temeljeno na poduzetničkim principima, proaktivnim pojedincima, koje će biti otvoreno za primjenu novih inovativnih tehnologija za kontrolu energetske učinkovitosti. Implementacija pametnih sustava kao što su sustavi za automatsko gašenje računala u slučaju neaktivnosti, gašenje rasvjete, automatsko reguliranje unutarnje temperature i sl. s tendencijom transformacije u pametne zgrade.

6. ZAKLJUČAK

Nestabilnost energetskih tržišta izazov je s kojim se suočavaju gotovo sva svjetska gospodarstva. Učinkovito upravljanje energijom postalo je jedan od načina za ublažavanje posljedica nestabilnosti koje se događaju na energetskim tržištima. Povećanje energetske učinkovitosti zajednički je cilj svih zemalja članica EU. Međutim, kao što je prikazano, pojam energetske učinkovitosti vrlo je širok i primjenjiv na različita područja od transporta, rasvjete do zgradarstva. U ovoj doktorskoj disertaciji fokus je na istraživanje energetske učinkovitosti u sektoru zgradarstva s fokusom na zgrade javnog sektora. Provođenje programa energetske obnove nije jednostavno i brojne su prepreke na tom put: zakonodavne, financijske, tehničke. Kada se te prepreke stave u kontekst javnog sektora one postaju još bitnije zbog specifičnosti djelovanja javnog sektora. Unatoč tome, zgrade javnog sektora imaju velik potencijal za prevladavanje tih prepreka i stvaranje pozitivnog okruženja po pitanju energetske učinkovitosti kako izvan javnog sektora tako i unutar javnog sektora. Kroz doktorsku disertaciju protezala su se sljedeća istraživačka pitanja:

- Postoji li značajno odstupanje između stvarne potrošnje energije zgrada javnog sektora u Republici Hrvatskoj i procijenjene potrošnje prema energetskim certifikatima zgrada javnog sektora?

- Ako odstupanje postoji, kako smanjiti odstupanja u predviđanju potrošnje energije u zgradama javnog sektora pomoću metoda strojnog učenja?

- Koji su glavni prediktori potrošnje energije zgrada javnog sektora koji mogu poslužiti donositeljima odluka o mjerama i ulaganjima u energetsku obnovu javnog sektora?

Kroz ostvareni znanstveni doprinos ove disertacije može se potvrditi da se odgovorilo na sva istraživačka pitanja. Doprinos ove doktorske disertacije može se promatrati s nekoliko aspekata. Kroz doprinos u istraživanju i utvrđivanju fenomena odstupanja između stvarno potrošene količine energije i proračunske potrošnje energije u zgradama javnog sektora u Republici Hrvatskoj. Iz pregleda literature može se zaključiti da se brojni istraživači bave ovim pitanjem. Unatoč tome nema jasnog konsenzusa zašto dolazi do odstupanja u potrošnji energije. Pojedini istraživači vide uzrok u načinu korištenja i režimu rada zgrade, drugi pak to pripisuju greškama prilikom projektiranja, odstupanjima koja su nastala prilikom izgradnje i

sl. Dobiveni rezultati odstupanja u ovom istraživanju konzistentni su s predstavljenim istraživanjima u ovom radu i ovise o namjeni zgrade koja se istražuje. Primjerice, odstupanja u zgradama obrazovne namjene su oko 40 % što su potvrdili i ostali istraživači.

Znanstveni je doprinos ove disertacije i izrada modela za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji energije. Motiv za izradu modela bio je poboljšati postojeći sustav za upravljanje potrošnjom energije kako bi imao sposobnost prepoznavanja energetski loših zgrada. Tako se omogućava na inovativan način izbor zgrada javnog sektora za energetsku obnovu i procjenu ušteda što bi pridonijelo poduzetničkom načinu upravljanja javnim sektorom i poticanje na inovativno djelovanje. Doprinos je ovog istraživanja i identifikacija glavnih prediktora potrošnje energije u zgradama javnog sektora koji se mogu koristiti kao kriteriji kod alokacije financijskih resursa za energetsku obnovu zgrada i tako povećati učinkovitost javnog sektora. Model omogućava uvid u svaku pojedinu zgradu i identifikaciju najznačajnijih varijabli. Time može poslužiti i kao podloga za procjenu financijskih ušteda i planiranje akcijskih planova energetske učinkovitosti. Indirektni je doprinos ovog istraživanja je u tome što može poslužiti kao podloga za planiranje nacionalne politike energetske učinkovitosti te može doprinijeti brže ostvarenje preuzetih obveza EU iz područja energetske učinkovitosti.

Provedenim istraživanjem uočena su i određena ograničenja. Kao glavno ograničenje nameće se kvaliteta podataka u ISGE sustavu, odnosno značajan broj nedostajućih vrijednosti, ali i vrijednosti izvan mogućih raspona čime su iz uzorka isključne brojne varijable, ali i zgrade javnog sektora. S obzirom na to da su korisnici zgrada javnog sektora obvezni kontinuirano unositi podatke u ISGE sustav, broj i kvaliteta unesenih podataka ukazuju na to da korisnici javnog sektora u najvećem dijelu marginaliziraju važnost toga te ne unose podatke u sustav. Nadalje, u ISGE sustav bilo bi korisno postaviti ograničenja prilikom unosa podataka tako da u situacijama kad korisnik unese vrijednosti koje su izvan mogućih intervala sam sustav reagira i onemogući takav unos.

Dobiveni rezultati modela za klasifikaciju zgrada javnog sektora prema stvarnoj potrošnji energije zadovoljavajući su, ali kao sljedeći korak nameće se i izrada modela neuronske mreže prema namjeni zgrade javnog sektora, npr. obrazovna namjena prema stvarnoj potrošnji primarne energije. Također, kao budući smjer istraživanja predlaže se i obrada podataka drugom metodom strojnog učenja (stabla odlučivanja i sl.), ali i daljnja selekcija varijabli koje ulaze u model.

Provedenim istraživanjem utvrdilo se da nema kvalitetnog upravljanja procesima energetske učinkovitosti bez svih uključenih dionika: od provoditelja programa do korisnika zgrada javnog sektora. U radu je izneseno nekoliko preporuka koje se mogu svesti pod zajednički nazivnik, a to je odgovornost svakog pojedinca u sustavu prema potrošnji energije. Uloga je čovjeka u potrošnji energije neminovna, stoga je potrebno educirati korisnike zgrada javnog sektora, uspostaviti menadžment koji će sustavno upravljati energijom unutar javnog sektora, stvoriti uvjete koji će potaknuti inovativno djelovanja i otvorenost u implementaciji novih tehnologija kojima bi se zgrade javnog sektora mogle pretvoriti u pametne zgrade i na taj način omogućilo bi se naprednije upravljanje energijom i potrošnjom energije u zgradama. Uvođenje predloženog inteligentnog modela u postojeći sustav za gospodarenje energijom može biti preduvjet za implementaciju novih tehnologija u javni sektor kao što je *internet stvari* (engl. *Internet of Things (IoT*)).

Ujedno, uvođenjem inovativnih modela za upravljanje energijom javni sektor pružio bi pozitivan primjer gospodarenja energijom, također promicala bi se važnost brige o energiji i kako što učinkovitije upravljati istom.

LITERATURA

1. Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon, 4*(11).
2. Aggarwal, C. C. (2018). *Neural networks and deep learning.* Springer.
3. Alam, M., Zou, P. X., Stewart, R. A., Bertone, E., Sahin, O. B., & Marshall, C. (2019). Government championed strategies to overcome the barriers to public building energy efficiency retrofit projects. *Sustainable Cities and Society, 44,* 56-69.
4. Al-Mofleh, A., Taib, S., Mujeebu, M. A., & Salah, W. (2009). Analysis of sectoral energy conservation in Malaysia. *Energy, 34*(6).
5. Alom, M. Z., Taha, T. M., Yakopcic, C., & Westberg, S. S. (2019). A State-of-the-Art Survey on Deep Learning Theory and Architectures. *Electronics, 3,* 292.
6. APN. (n.d.). *Informacijski sustav za gospodarenje energijom – ISGE*. Dostupno na: https://apn.hr/gospodarenje-energijom-isge/informacijski-sustav-za-gospodarenje-energijom (pristupljeno 18.04.2021.)
7. Arcipowska, A., Mariottini, F. (2016). The EU Building Stock Observatory: A New Tool to Support Europe's. *ACEEE Summer Study on Energy Efficiency in Buildings*.
8. Bašić, B. D., Čupić, M., & Šnajder, J. (2008). *Umjetne neuronske mreže.* Zagreb: Fakultet elektrotehnike i računarstva.
9. Bengio, Y., Goodfellow, I., & Courville, A. (2017). *Deep learning.* Cambridge, MA, USA: MIT press.
10. Božić, H., Vuk, B., & Novosel, B. (2009). Indikatori energetske učinkovitosti. *Journal of Energy: Energija, 58*(5).
11. Brownlee, J. (2018). *Better deep learning: train faster, reduce overfitting, and make better predictions.* Machine Learning Mastery.
12. Buildings Performance Institute Europe (2020). The European renovation wave: from words to action.
13. Buscema, P., Massini, G., Breda, M., Lodwick, W., Newman, F., & Asadi-Zeydabadi, M. (2018). Artificial Neural Networks. In *Artificial Adaptive Systems Using Auto Contractive Maps. Studies in Systems, Decision and Controls.* Cham: Springer.
14. CarbonBuzz. (n.d.). *The performance gap*. Dostupno na: https://www.carbonbuzz.org/casestudiestab.jsp (pristupljeno 17.04.2021.)

15. Centar za praćenje poslovanja energetskog sektora i investicija. (n.d.). *Poboljšanja energetske učinkovitosti u Hrvatskoj*. Dostupno na: https://www.enu.hr/ee-u-hrvatskoj/20-20-20-i-dalje/rezultati/energetska-ucinkovitost-hr/ (24.11.2020.)
16. Centar za praćenje poslovanja energetskog sektora i investicija. (n.d.). *Strateški ciljevi Europske Unije do 2030. godine*. Dostupno na: https://www.enu.hr/ee-u-hrvatskoj/20-20-20-i-dalje/ciljevi-eu-2030/ (pristupljeno 15.04.2021.)
17. Chhabra, G., Vashisht, V., & Ranjan, J. (2017). A comparison of multiple imputation methods for data with missing values. *Indian Journal of Science and Technology, 10*(19), 1-7.
18. Chipeta, E. M., Surujlal, J. (2017). Influence of attitude, risk taking propensity and proactive personality on social entrepreneurship intentions. *Polish Journal of Management Studies, 15*.
19. Cozza, S., Chambers, J., Deb, C., Scartezzini, J. L., Schlüter, A., & Patel, M. K. (2020). Do energy performance certificates allow reliable predictions of actual energy consumption and savings?Learning from the Swiss national database. *Energy and Buildings, 224*.
20. Čupić, M. (2019). *Duboko učenje Optimizacija parametara modela.* Fakultet elektrotehnike i računarstva. Dostupno na: http://www.zemris.fer.hr/~ssegvic/du/du3optimization.pdf (pristupljeno 20.04.2021.)
21. D'Agostino, D., Cuniberti, B., & Bertoldi, P. (2017). Energy consumption and efficiency technology measures in European non-residential buildings. *Energy and Buildings, 153*, 72-86.
22. Danso, A., Adomako, S., Damoah, J. O., & Uddin, M. (2016). Risk-taking propensity, network ties and firm performance in an emerging economy. *The Journal of Entrepreneurship, 25*(2), 155-183.
23. Daut, M. A., Hassan, M. Y., Abdullah, H., Rahman, H. A., Abdullah, M. P., & Hussin, F. (2017). Building electrical energy consumption forecasting analysis using conventional and artificial intelligence methods: A review. *Renewable and Sustainable Energy Reviews, 70*, 1108-1118.
24. De Wilde, P. (2014). The gap between predicted and measured energy performance of buildings: A framework for investigation. *Automation in construction, 41*, 40-49.
25. Demircioglu, M. A., Chowdhury, F. (2021). Entrepreneurship in public organizations: the role of leadership behavior. *Small Business Economics, 57*(3), 1107-1123.

26. Directorate-General for Energy. (2016). *Mapping and analyses of the current and future (2020 - 2030) heating/cooling fuel deployment (fossil/renewables).* Europska komisija.
27. Direktiva 2018/844 o energetskoj učinkovitosti. (2018). Europski parlamenti i Vijeće Europske unije. Dostupno na: https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=celex:32018L0844 (pristupljeno 13.04.2021.)
28. Direktiva 2010/31/EU o energetskoj učinkovitosti zgrada. (2010). Europski parlament i Vijeće Europske unije. Dostupno na: https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=celex%3A32010L0031 (pristupljeno 12.11.2020.)
29. Direktiva o energetskoj učinkovitosti (2012/27/EU). (2021). Europski parlament i Vijeće Europske unije. Dostupno na: https://eur-lex.europa.eu/legal-content/hr/TXT/?uri=celex:32012L0027 (pristupljeno 12.11.2020)
30. Dongare, A. D., Kharde, R. R., & Kachare, A. D. (2012). Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT), 2*(1), 189-194.
31. Droutsa, K., Balaras, C., Lykoudis, S., Kontoyiannidis, S., Dascalaki, E., & Argiriou, A. (2020). Baselines for Energy Use and Carbon Emission Intensities in Hellenic Nonresidential Buildings. *Energies, 13*(8), 2100.
32. Državni zavod za statistiku. (2001). *Nacionalna klasifikacija vrsta građevina - NKVG.* Dostupno na: https://www.dzs.hr/app/KLASUS/Docs/NKVG_Publikacija.pdf (pristupljeno 15.04.2021.)
33. Ekici, B. B., Aksoy, U. T. (2009). Prediction of building energy consumption by using artificial neural networks. *Advances in Engineering Software, 40*(5), 356-362.
34. Enerdata. (2020). *Definition of data and energy efficiency indicators in ODYSSEE data base.* Glossary energy efficiency. Odyssee-Mure
35. Energetski institut Hrvoje Požar. (2020). *Godišnji energetski pregled – Energija u Hrvatskoj 2020*, Ministarstvo gospodarstva i održivog razvoja
36. Environmental and Energy Study Institute. (n.d.). *Energy Efficiency*. Dostupno na: https://www.eesi.org/topics/energy-efficiency/description (14.04.2021.)
37. Europska komisija. (2019). *Preporuka komisije (EU) 2019/786 o obnovi zgrada.* Službeni list Europske unije. Dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/HTML/?uri=CELEX:32019H0786&from=EN (pristupljeno 15.04.2021.)

38. Europska komisija. (2021). *2030 climate & energy framework*. Dostupno na: https://ec.europa.eu/clima/eu-action/climate-strategies-targets/2030-climate-energy-framework_hr (pristupljeno 14.04.2021.)
39. Europska komisija. (n.d.). *Energy union*. Dostupno na: https://energy.ec.europa.eu/topics/energy-strategy/energy-union_en (pristupljeno 13.04.2021)
40. Europska komisija. (n.d.). *Diversification of gas supply sources and routes*. Dostupno na: https://energy.ec.europa.eu/topics/energy-security/diversification-gas-supply-sources-and-routes_en (pristupljeno 13.04.2021.)
41. Europska komisija. (2016). *Mapping and analyses of the current and future (2020 - 2030) heating/cooling fuel deployment (fossil/renewables). Dostupno na: https://energy.ec.europa.eu/mapping-and-analyses-current-and-future-2020-2030-heatingcooling-fuel-deployment-fossilrenewables-1_en* (pristupljeno 16.04.2021.)
42. Europska komisija. (n.d.). *EU Building Stock Observatory*. Dostupno na: https://energy.ec.europa.eu/topics/energy-efficiency/energy-efficient-buildings/eu-building-stock-observatory_en (pristupljeno 16.04.2021.)
43. Europska komisija. (n.d.). *Measures to improve the building stock*. Dostupno na: https://energy.ec.europa.eu/topics/energy-efficiency/energy-efficient-buildings/energy-performance-buildings-directive_en#measures-to-improve-the-building-stock (pristupljeno 15.04.2021.)
44. Eurostat. (2018). *Glossary:Building*. Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Glossary:Building (pristupljeno 16.04.2021.)
45. Eurostat. (2020). *Energy, Transport and Environment Statistics 2020 Edition.* doi:10.2785/522192. Statistical Books, Luxembourg: Publications Office of the European Union
46. Eurostat. (2021). *Energy efficiency statistics.* Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Energy_efficiency_statistics#Primary_energy_consumption_and_distance_to_2020_and_2030_targets (pristupljeno 14.04.2021.)
47. Eurostat. (2021). *Final energy consumption by sector*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/ten00124/default/table?lang=en (13.03.2021.)

48. Eurostat. (n.d.). *Final energy consumption*. Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Glossary:Final_energy_consumption (24.11.2020.)
49. Fatur Šikić, T. (2020). Utjecaj potrošnje energije na ekonomski rast u razvijenim i post-tranzicijskim zemljama Europske unije. *Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu, 38*(2), 475-497.
50. Ferlito, S., Atrigna, M., Graditi, G., De Vito, S., Salvato, M., Buonanno, A., & Di Francia, G. (2015). Predictive models for building's energy consumption: An Artificial Neural Network (ANN) approach. *2015 xviii aisem annual conference*. IEEE, 1-4.
51. Finlay, S. (2014). *Predictive analytics, data mining and big data: Myths, misconceptions and methods.* Springer.
52. Fond za zaštitu okoliša i energetsku učinkovitost. (n.d.). *Energetska obnova javnih zgrada*. Dostupno na: https://www.fzoeu.hr/hr/energetska-obnova-javnih-zgrada/7699 (pristupljeno 14.04.2021.)
53. Foucquier, A., Sylvain, R., Suard, F., Stephan, L., & Arnaud, J. (2013). State of the art in building modelling and energy performances prediction: A review. *Renewable and Sustainable Energy Reviews, 23*, 272-288.
54. Geissler, S., G Charalambides, A., & Hanratty, M. (2019). Public Access to Building Related Energy Data for Better Decision Making in Implementing Energy Efficiency Strategies: Legal Barriers and Technical Challenges. *Energies, 12*(10), 2029.
55. Gelo, T. (2010). *Makroekonomika energetskog tržišta.* Zagreb: EFZG Occasional Publications (Department of Macroeconomics).
56. Glorot, X., Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. *Proceedings of the thirteenth international conference on artificial intelligence and statistics*. JMLR Workshop and Conference Proceedings, 249-256.
57. Gürol, Y., Atsan, N. (2006). Entrepreneurial characteristics amongst university students: Some insights for entrepreneurship education and training in Turkey. *Education+ training*.
58. Gynther, L., Eichhammer, W. (2016). *Energy Efficiency and the Public Sector*. Odyssee - Mure.
59. Has, A., Zekić-Sušac, M. (2017). Modelling energy efficiency of public buildings by neural networks and its economic implications. *Proceedings of the 14th International Symposium on Operations Research in Slovenia*, Bled, 461- 466.

60. Hayter, C. S., Link, A. N., & Scott, J. T. (2018). Public-sector entrepreneurship. *Oxford Review of Economic Policy, 34*(4), 676–694.
61. Herrando, M., Cambra, D., Navarro, M., de la Cruz, L. M., & Zabalza, I. (2016). Energy Performance Certification of Faculty Buildings in Spain: The gap between estimated and real energy consumption. *Energy Conversion and Management, 125*, 141-153.
62. Herring, H. (2006). Energy efficiency—a critical view. *Energy*, 10-20.
63. Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation, 18*(7), 1527-1554.
64. Hitchcock, G., Hughes, D. (2002). *Research and the teacher: A qualitative introduction to school-based research.* Routledge.
65. Hwang, J., Suh, D., & Otto, M. O. (2020). Forecasting electricity consumption in commercial buildings using a machine learning approach. *Energies, 13*(22), 5885.
66. International Energy Agency. (2014). *Capturing the Multiple Benefits of Energy Efficiency: A Guide to Quantifying the Value Added.* Paris: IEA.
67. International Partnership for Energy Efficiency Cooperation - IPEEC. (2019). *Building Energy Performance Gap Issues: An International Review.* Dostupno na: https://www.energy.gov.au/sites/default/files/the_building_energy_performance_gap-an_international_review-december_2019.pdf (pristupljeno 17.04.2021.)
68. Jakovac, P. (2018). Causality between energy consumption and economic growth: Literature review. In *Proceedings of the 5th International Conference on Education and Social Sciences, Istanbul*.
69. Jakovac, P., Vlahinić Lenz, N. (2015). Uloga energije s aspekta ekonomske teorije. *Ekonomski pregled, 66*(6), 527-557.
70. Johnson, P., Clark, M. (2006). Editors' introduction:Mapping the terrain: An overview of business and management research methodologies'. *Business and Management Research*.
71. Kalogirou, S. A. (2009). Artificial neural networks and genetic algorithms in energy applications in buildings. *Advances in Building Energy Research, 3*(1), 83-119.
72. Katić, D., Krstić, H., & Marenjak, S. (2021). Energy performance of school buildings by construction periods in federation of Bosnia and Herzegovina. *Buildings, 11*(2), 42.
73. Kavlakoglu, E. (2020). *AI vs. Machine Learning vs. Deep Learning vs. Neural Networks: What's the Difference?* Dostupno na: https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks (pristupljeno 20.04.2021.)
74. Kesner-Škreb, M. (2006). Državni sektor. *Financijska teorija i praksa*, 93-94.

75. Kirzner, I. M. (1978). Entrepreneurship, entitlement, and economic justice. *Eastern Economic Journal*, 9-25.
76. Kramberger, T., Nožica, B., Dodig, I., & Cafuta, D. (2019). Pregled tehnologija u neuronskim mrežama. *Polytechnic and design, 7*(1), 25-32.
77. KrishnaKumar, K. (2021). Robustness of neural networks. In *World Congress On Neural Networks-San Diego*. Routledge, 422.
78. Krstić, H., Teni, M. (2018). Algorithm for constructional characteristics data cleansing of large-scale public buildings database. *WIT Transactions on The Built Environment*, 213-224.
79. Krstić, H., Teni, M. (2018). Analysis of energy performance and buildings characteristics obtained from Croatian energy management information system. *Int. J. Struct. Civ. Eng. Res, 7*, 252-258.
80. Kuratko, D., Morris, M., & Covin, J. (2011). *Corporate Innovation & Entrepreneurship.*
81. Kurenkov, A. (2020). A Brief History of Neural Nets and Deep Learning. *Skynet Today*. Dostupno na: https://www.skynettoday.com/overviews/neural-net-history (pristupljeno 18.04.2021.)
82. Kursa, M. B., Rudnicki, W. R. (2010). Feature selection with the Boruta package. *Journal of statistical software, 36*, 1-13.
83. Lackéus, M., Lundqvist, M., Williams Middleton, K., & Inden, J. (2020). The entrepreneurial employee in public and private sector–What, Why, How. *Luxembourg: Publications Office of the European Union*.
84. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning.*Nature, 521*(7553), 436-444.
85. Leyden, D. P., Link, A. N. (2015). *Public sector entrepreneurship: US technology and innovation policy.* Oxford University Press, USA.
86. Li, C., Ding, Z., Zhao, D., Yi, J., & Zhang, G. (2017). Building energy consumption prediction: An extreme deep learning approach. *Energies, 10*(10), 1525.
87. Li, Q., Meng, Q., Cai, J., Yoshino, H., & Mochida, A. (2009). Predicting hourly cooling load in the building: A comparison of support vector machine and different artificial neural networks. *Energy Conversion and Management, 50*(1), 90-96.
88. Liang, S., Sun, R., Li, Y., & Srikant, R. (2018). Understanding the loss surface of neural networks for binary classification. *International Conference on Machine Learning*, 2835-2843.
89. Lillicrap, T. P., Santoro, A., Marris, L., Akerman, C. J., & Hinton, G.. (2020). Backpropagation and the brain. *Nat Rev Neurosci, 21*(6), 335–346.

90. Link, A. (2016). Public sector entrepreneurship: introduction to the special section. *Econ Polit Ind, 43*, 355–356.
91. Liu, M., Chen, L., Du, X., Jin, L., & Shang, M. (2021). Activated Gradients for Deep Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*.
92. Majcen, D., Itard, L. C., & Visscher, H. (2013). heoretical vs. actual energy consumption of labelled dwellings in the Netherlands: Discrepancies and policy implications. *Energy policy, 54*, 125-136.
93. Mehmood, T., Liland, K. H., Snipen, L., & Sæbø, S. (2012). A review of variable selection methods in Partial Least Squares Regression. *Chemometrics and intelligent laboratory systems*, 62-69.
94. Melcher, K., & Silipo, S. (n.d.). *Missing Value Imputation – A Review*. Dostupno na: https://www.kdnuggets.com/2020/09/missing-value-imputation-review.html (pristupljeno 18.04.2021.)
95. Menezes, A. C., Cripps, A., Bouchlaghem, D., & Buswell, R. (2012). Predicted vs. actual energy performance of non-domestic buildings: Using post-occupancy evaluation data to reduce the performance gap. *Applied energy, 97*, 355-364.
96. Miljenović, D., Kutnjak, G., & Jakovac, P. (2020). Determiniranje obilježja djelotvornosti javnog sektora i javnog menadžmenta. *Zbornik Veleučilišta u Rijeci*, 295-311.
97. Ministarstvo prostornog uređenja, graditeljstva i državne imovine. (n.d.). *IEC - Informacijski sustav energetskih certifikata*. Dostupno na: https://mpgi.gov.hr/o-ministarstvu/djelokrug/energetska-ucinkovitost-u-zgradarstvu/iec-informacijski-sustav-energetskih-certifikata/8357 (pristupljeno 17.04.2021.)
98. Ministarstvo prostornoga uređenja, graditeljstva i državne imovine. (n.d.). *Zgrade gotovo nulte energije nZEB*. Dostupno na: https://mpgi.gov.hr/o-ministarstvu/djelokrug/energetska-ucinkovitost-u-zgradarstvu/zgrade-gotovo-nulte-energije-nzeb/10504 (pristupljeno 15.04.2021.)
99. Mishra, A. (2018). *Metrics to Evaluate your Machine Learning Algorithm*. Dostupno na: https://towardsdatascience.com/metrics-to-evaluate-your-machine-learning-algorithm-f10ba6e38234 (pristupljeno 20.04.2021.)
100. Mocanu, E., Nguyen, P. H., Gibescu, M., & Kling, W. L. (2014). Comparison of machine learning methods for estimating energy consumption in buildings. *2014 International conference on probabilistic methods applied to power systems (PMAPS)*. IEEE, 1- 6.
101. Nel, J. (2016). *The research paradigms: Positivism*. Dostupno na: https://www.intgrty.co.za/2016/07/19/the-research-paradigms

positivism/#:~:text=Positivists%20believe%20that%20knowledge%20can,use%20of%20the%20scientific%20method.&text=A%20positivist%20approach%20emphasises%20experimentation,This%20implies%20a%20quantit (pristupljeno 18.04.2021.)

102. Nielsen, M. A. (2015). *Neural networks and deep learning* (Vol. 25). San Francisco, CA, USA: Determination press.
103. Nnamoko, N., Arshad, F., England, D., Vora, J., & Norman, J. (2014). Evaluation of Filter and Wrapper Methods for Feature Selection in Supervised Machine Learning. *Age, 21*(81), 33-2.
104. Ockwell, D.G. (2008.). Energy and economic growth: Grounding our understanding in physical reality. *Energy Policy, 36*, 4600-4604.
105. OECD. (2021). *Non-residential buildings – UN*. Dostupno na: https://stats.oecd.org/glossary/detail.asp?ID=1833 (pristupljeno 16.04.2021.)
106. Ostrom, E. (1964). Public Entrepreneurship: A Case Study in Ground Water Basin Management'. *University of California, Los Angeles, CA, unpublished PhD dissertation*.
107. Patterson, M. G. (1996). What is energy efficiency?: Concepts, indicators and methodological issues. *Energy policy*, 377-390.
108. Patton, N. (n.d.). *How Can Public Sector Buildings Improve Energy Efficiency?*. Dostupno na: https://www.buildingsiot.com/blog/how-can-public-sector-buildings-improve-energy-efficiency-bd (pristupljeno 17.04.2021.)
109. Pegg, I. M. (2007). Post-occupancy performance of five low-energy schools in the UK/Discussion. *ASHRAE transactions, 113*(3).
110. Pereira, R., Ribeiro, M. C., Rua, O. M., & Martins, D. (2019). Is There Entrepreneurship Within the Public Sector? *Entrepreneurial Orientation and Opportunities for Global Economic Growth*, 92-118.
111. Pravilnik o energetskom pregledu zgrade i energetskom certificiranju. NN 88/17, NN 90/20, NN 01/21, NN 45/21.
112. Rana, A., Rawat, A. S., Bijalwan, A., & Bahuguna, H. (2018). Application of Multi layer (Perceptron) Artificial Neural. *International conference on research in intelligent and computing in engineering (RICE)*. IEEE. 1-6.
113. Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). Model-agnostic interpretability of machine learning. *arXiv preprint arXiv:1606.05386.*
114. Rics. (2020). *Energy efficiency of the building stock in the EU*. Dostupno na: https://www.rics.org/eu/news-insight/latest-news/news-opinion/energy-efficiency-of-the-building-stock-in-the-eu/ (pristupljeno 17.04.2021.)

115. Ritchie, H., Roser, M. (2020). Energy. *Our World in Data*. Dostupno na: https://ourworldindata.org/energy (24.11.2020.)
116. Rumelhart, D., Hinton, G. & Williams, R. (1986). Learning representation by backpropagation errors, *Nature*. *323*, 533–536.
117. Rousselot, M., Pinto Da Rocha, F. (2021). *Energy efficiency trends in buildings in the EU.* Odyssee - Mure. Dostupno na: https://www.odyssee-mure.eu/publications/policy-brief/buildings-energy-efficiency-trends.pdf (pristupljeno 17.04.2021.)
118. Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747.*
119. Runge, J., Zmeureanu, R. (2019). Forecasting energy use in buildings using artificial neural networks: A review. *Energies*, *12*(17), 32-54.
120. Salleh, F., Ibrahim, M. (2011). Demographic characteristics differences of risk taking propensity among micro and small business owners in Malaysia. *International Journal of Business and Social Science, 2*(9).
121. Saunders, M., Lewis, P., & Thornhill, A. (2019). *Research methods for business students, 8th edition.* London: Pearson.
122. Schumpeter, J A. (1934). *The Theory of Economic Development: An Inquiry into Profits, Capital, Credit, Interest, and the Business Cycle.* Cambridge, MA.: Harvard University Press.
123. Schumpeter, J. A. (1942). Capitalism, Socialism and Democracy. Routledge
124. Seyedzadeh, S., Rahimian, F. P., Glesk, I., & Roper, M. (2018). Machine learning for estimation of building energy consumption and performance: a review. *Visualization in Engineering, 6*(1), 1-20.
125. Shapi, M. K., Ramli, N. A., & Awalin, L. J. (2021). Energy consumption prediction by using machine learning for smart building: case study in Malaysia. *Developments in the Built Environment, 5*, 100037.
126. Shi, X., Si, B., Zhao, J., Tian, Z., Wang, C., Jin, X., & Zhou, X. (2019). Magnitude, causes, and solutions of the performance gap of buildings: A review. *Sustainability, 11*(3), 937.
127. Shrestha, A., Mahmood, A. (2019). Review of Deep Learning Algorithms. *IEEE access*, 53040-53065.
128. Sikalieh, D., Mokaya, S. O., & Namusonge, M. (2012). The concept of entrepreneurship; in pursuit of a universally acceptable definition. *International Journal of Arts and Commerce, 1*(6).

129. Skansi, S. (2018). *Introduction to Deep Learning From Logical Calculus to Artificial Intelligence.* Springer.
130. Tehnički propis o racionalnoj uporabi energije i toplinskoj zaštiti u zgradama. NN 128/15, 70/18, 73/18, 86/18, NN 102/20.
131. Tommerup, H., Rose, J., & Svendsen, S. (2007). Energy-efficient houses built according to the energy performance requirements introduced in Denmark in 2006. *Energy and Buildings, 39*(10), 1123-1130.
132. U.S. Energy Information Administration (EIA). (2021). Dostupno na: https://www.eia.gov/energyexplained/use-of-energy/ (07.04.2021.)
133. Ujević Andrijić, Ž. (2019). Osvježimo znanje: Umjetne neuronske mreže. *Kemija u industriji: Časopis kemičara i kemijskih inženjera Hrvatske*, 219-220.
134. Van Dronkelaar, C., Dowson, M., Burman, E., Spataru, C., & Mumovic, D. (2016). A Review of the Energy Performance Gap and Its Underlying Causes in Non-Domestic Buildings. *Frontiers in Mechanical Engineering, 1*.
135. Vani, S., Rao, T. M. (2019). An experimental approach towards the performance assessment of various optimizers on convolutional neural network. *3rd international conference on trends in electronics and informatics (ICOEI).* 331-336.
136. Venkatesh, B., Anuradha, J. (2019). A Review of Feature Selection and Its Methods. *Cybernetics and Information Technologies, 19*(1), 3-26.
137. Vijeće Europske unije. (2021). *Čista energija: poticanje prijelaza na niskougljično gospodarstvo*. Dostupno na: https://www.consilium.europa.eu/hr/policies/energy-union/ (pristupljeno 13.04.2021.)
138. Vlada Republike Hrvatske. (2017). *Odluka o donošenju Programa energetske obnove zgrada javnog sektora u razdoblju od 2016. do 2020.* NN 22/2017-508.
139. Volt, J., Zuhaib, S., Schmatzberger, S., & Toth, Z. (2020). Energy Performance Certificates Assessing their Status and Potential. *Building Performance Institute Europe: Brussels, Belgium*.
140. Walczak, S. (2018). Artificial Neural Networks. *Encyclopedia of Information Science and Technology, Fourth Edition*, 120-131.
141. Wang, S., Tang, J., & Liu, H. (2015). Embedded unsupervised feature selection. In Proceedings of the AAAI Conference on Artificial Intelligence. *29* (1). *In Proceedings of the AAAI Conference on Artificial Intelligence, 29.*

142. Wang, Y., Wang, L., Chang, Q., & Yang, C. (2020). Effects of direct input–output connections on multilayer perceptron neural networks for time series prediction. *Soft Comput, 24*, 4729–4738.
143. Wong, S. L., Wan, K. K., & Lam, T. N. (2010). Artificial neural networks for energy analysis of office buildings with daylighting. *Applied Energy, 87*(2), 551-557.
144. Wu, Y. C., Feng, J. W. (2018). Development and Application of Artificial Neural Network. *Wireless Personal Communications,* 1645-1656.
145. Ying, X. (2019). An overview of overfitting and its solutions. *Journal of Physics: Conference Series, 1168*(2).
146. Zaheer, R., Shaziya, H. (2019). A Study of the Optimization Algorithms in Deep Learning. *Third International Conference on Inventive Systems and Control (ICISC),* 536-539.
147. Zakon o energetskoj učinkovitosti (NN 127/14, 116/18, 25/20, 32/21, 41/21)
148. Zakon o gradnji (NN 153/13, 20/17, 39/19, 125/19)
149. Zekić - Sušac, M. (2018). *Sustavi poslovne inteligencije - Neuronske mreže.* Nastavni materijali. Dostupno na: https://arhiva-2021.loomen.carnet.hr/course/view.php?id=278 (pristupljeno 20.04.2021.)
150. Zekić-Sušac, M. (2000). Neuronske mreže u predviđanju profitabilnosti ulaganja. *Doktorska disertacija*.
151. Zekić-Sušac, M. (2017). Machine learning in energy consumption management. *Proceedings of the 14th International Symposium on Operational Research in Slovenia,* Bled, 7-17.
152. Zekić-Sušac, M., Has, A., & Knežević, M. (2021). Predicting energy cost of public buildings by artificial neural networks, CART, and random forest. *Neurocomputing,* 223-233.
153. Zekić-Sušac, M., Mitović, S., & Has, A. (2021). Machine learning based system for managing energy efficiency of public sector as an approach towards smart cities. *International journal of information management, 58*.
154. Zhang, Z., Beck, M. W., Winkler, D. A., Huang, B., Sibanda, W., & Goyal, H. (2018). Opening the black box of neural networks: methods for interpreting neural network models in clinical applications. *Annals of translational medicine, 6*(11).
155. Žukauskas, P., Vveinhardt, J., & Andriukaitienė, R. (2018). *Philosophy and paradigm of scientific research , 121*.

POPIS SLIKA

Slika 1 Ukupna potrošnja primarne energije u svijetu 9
Slika 2 Potrošnja primarne energije prema geografskim regijama 9
Slika 3 Svjetska neposredna potrošnja energije po sektorima 10
Slika 4 Potrošnja primarne energije - EU 27 19
Slika 5 Potrošnja finalne energije – EU 27 20
Slika 6 Prosječna promjena u potrošnji primarne energije u razdoblju od 2017. do 2019. godine 23
Slika 7 Prosječna promjena u potrošnji finalne energije u 25
Slika 8 Provedba programa energetske obnove javnih zgrada (APN, 2020) 47
Slika 9 Istraživački luk 53
Slika 10 Istraživački okvir doktorske disertacije 58
Slika 11 Dijagram istraživačkog procesa 59
Slika 12 Proces prikupljanja podataka 61
Slika 13 Algoritam obrade i čišćenja podataka o građevinskim i uporabnim obilježjima 64
Slika 14 Zgrade javnog sektora kao dio kulturne baštine 69
Slika 15 Razdoblje izgradnje zgrade javnog sektora 69
Slika 16 Ilustrativni prikaz Matrice konfuzije 74
Slika 17 Računanje u Višeslojnoj perceptron mreži 80
Slika 18 Plitke vs duboke neuronske mreže 83
Slika 19 Višeslojna neuronska mreže – duboko učenje 84
Slika 20 Koraci u izgradnji modela neuronske mreže 86
Slika 21 Poduzorak za utvrđivanje odstupanja u potrošnji toplinske energije 94
Slika 22 Definiranje Klase prema stvarnoj primarnoj potrošnji energije 111
Slika 23 Struktura ciljne varijable Klasa 114
Slika 24 Algoritam predprocesuiranja i pripreme podataka i varijable cilja 115
Slika 25 Odabir statističkog testa ovisno o tipu varijable 116
Slika 26 Koraci u izgradnji modela neuronske mreže u provedenom istraživanju 119
Slika 27 Algoritam 2 Modeliranje neuronskih mreža 123
Slika 28 Arhitektura odabranog modela neuronske mreže Model 3 128
Slika 29 Utjecaj ulaznih varijabli na ciljnu varijablu modela 132
Slika 30 Značajnost varijabli na lokalnoj razini 135

POPIS TABLICA

Tablica 1 Pokazatelji energetske učinkovitosti 13
Tablica 2 Potrošnja primarne energije u zemljama članicama EU 22
Tablica 3 Potrošnja finalne energije u zemljama članicama EU 24
Tablica 4 Podsektori tercijarnog sektora 29
Tablica 5 Specifična godišnja potrebna energija za grijanje 32
Tablica 6 Specifična godišnja primarna energija, E_{prim} izražena u kWh/m²a. 32
Tablica 7 Pojmovno određivanje zgrada javnog sektora 42
Tablica 8 Prepreke u provođenju programa energetske obnove zgrada javnog sektora 49
Tablica 9 Prikaz istraživačkih filozofija u poslovnom istraživanju 55
Tablica 10 Raspon mogućih vrijednosti građevinskih 65
Tablica 11 Pregled varijabli i deskriptivna statistika radi preglednosti nalazi se u prilogu... 67
Tablica 12 Zgrade javnog sektora prema namjeni 68
Tablica 13 Zgrade javnog sektora prema regiji 68
Tablica 14 Rekonstrukcija zgrada javnog sektora 70
Tablica 15 Broj zaposlenih u zgradama javnog sektora 70
Tablica 16 Broj korisnika u zgradama javnog sektora 71
Tablica 17 Energetski certifikat u zgradama javnog sektora 71
Tablica 18 Deskriptivna statistika stvarne i proračunske potrošnje toplinske energije 95
Tablica 19 Deskriptivna statistika - odstupanje u potrošnji energije 97
Tablica 20 Raspon odstupanja u potrošnji energije 98
Tablica 21 Pojedinačno odstupanje u potrošnji energije 98
Tablica 22 Odstupanje u potrošnji prema namjeni zgrada javnog sektora 100
Tablica 23 Odstupanje u potrošnji energije - Proračunska potrošnja energije > Stvarna potrošnja energije 103
Tablica 24 Raspon odstupanja u potrošnji energije – 104
Tablica 25 Odstupanje u potrošnji prema namjeni zgrada javnog sektora - proračunska potrošnja energije > stvarna potrošnja energije 105
Tablica 26 Specifična godišnja primarna energija, E_{prim} kWh/m²a 112
Tablica 27 Definirani tehnički sustavi za proračun do primarne energije za referentne klimatske podatke za pojedine vrste zgrade 113
Tablica 28 Klasificiranje zgrade javnog sektora prema 113
Tablica 29 Selekcija varijabli filter metodom i metodom omotača varijabli. 118

Tablica 30 Struktura uzorka za modeliranje 120
Tablica 31 Optimalni rezultati Modela 1, Modela 2, Modela..... 124
Tablica 32 Usporedba metrika uspješnosti za Model 1, Model 2 i Model 3 127
Tablica 33 Prikaz najboljeg rezultata Modela 3..... 129
Tablica 34 Matrica konfuzije za odabrani model..... 130
Tablica 35 Matrica konfuzije - proračunska i stvarna potrošnja energije..... 141

PRILOZI

Prilog 1 - Tablica 11 *Pregled varijabli i deskriptivna statistika*

Tablica 11 Pregled varijabli i deskriptivna statistika

	Naziv varijable	Šifra varijable	N	Deskriptivna statistika		Tip varijable
1.	Udio u ukupnoj površini zgrade [%]	Udio_uk_po	2192	Minimum	10,00	kontinuirana
				Prvi kvartil	100,00	
				Medijan	100,00	
				Srednja vrijednost	97,56	
				Treći kvartil	100,00	
				Maksimum	100,00	
2.	Ukupna ploština neto podne površine grijanog dijela zgrade	Uk_plo_net	2192	Minimum	50,40	kontinuirana
				Prvi kvartil	267,20	
				Medijan	860,20	
				Srednja vrijednost	1622,80	
				Treći kvartil	2092,90	
				Maksimum	60744,00	
3.	Broj radnih dana u tjednu	Br_dn_tj	2192	Minimum	5	kontinuirana
				Prvi kvartil	6	
				Medijan	6	
				Srednja vrijednost	5,93	
				Treći kvartil	6	
				Maksimum	7	
4.	Broj radnih sati u danu	Br_rs_dn	2192	Minimum	8	kontinuirana
				Prvi kvartil	8	
				Medijan	8	
				Srednja vrijednost	10,05	
				Treći kvartil	8	
				Maksimum	24	
5.	Ploština bruto podne površine zgrade [m²]	Pl_br_pod	2192	Minimum	63,00	kontinuirana
				Prvi kvartil	327,60	
				Medijan	991,10	
				Srednja vrijednost	1981,50	
				Treći kvartil	2454,70	
				Maksimum	71104,0	
6.	Oplošje grijanog dijela zgrade A [m²]	Op_grij_zg	2192	Minimum	36,00	kontinuirana
				Prvi kvartil	841,50	
				Medijan	2188,90	
				Srednja vrijednost	3061,60	
				Treći kvartil	3780,70	
				Maksimum	85500,00	
7.	Bruto obujam grijanog dijela zgrade kojem je oplošje A [m³]	Br_obuj_grij	2192	Minimum	70,90	kontinuirana
				Prvi kvartil	861,20	
				Medijan	2868,00	
				Srednja vrijednost	6638,90	
				Treći kvartil	8745,80	
				Maksimum	189825,00	
8.	Broj etaža	Br_et	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	1,00	
				Medijan	2,00	
				Srednja vrijednost	2,24	
				Treći kvartil	3,00	
				Maksimum	11,00	

9.	Unutarnja projektna temperatura u sezoni grijanja [°C]	Un_temp_gri	2192	Minimum	16,00	kontinuirana
				Prvi kvartil	20,00	
				Medijan	20,00	
				Srednja vrijednost	20,31	
				Treći kvartil	20,00	
				Maksimum	25,00	
10.	Temperatura na mjernoj stanici	Temp_mjer_st	2192	Minimum	8,80	kontinuirana
				Prvi kvartil	10,90	
				Medijan	11,04	
				Srednja vrijednost	12,01	
				Treći kvartil	12,70	
				Maksimum	16,60	
11.	Faktor oblika zgrade, F_0 [m^{-1}]	F_o	2192	Minimum	0,07	kontinuirana
				Prvi kvartil	0,46	
				Medijan	0,70	
				Srednja vrijednost	0,72	
				Treći kvartil	0,95	
				Maksimum	1,83	
12.	Koeficijent transmisijskog. topl. gubitka po jed. oplošja grij. dijela zgrade H'tr,iz [W/m²K]	Koef_trans	2192	Minimum	0,10	kontinuirana
				Prvi kvartil	0,24	
				Medijan	0,24	
				Srednja vrijednost	0,45	
				Treći kvartil	0,24	
				Maksimum	4,48	
13.	Najveća dopuštena godišnja potrebna toplinska energija za grijanje nestambene zgrade, $Q'_{H,nd,dop}$ [kWh/m³a]	$Q'_{H,nd,dop}$	2192	Minimum	16,42	kontinuirana
				Prvi kvartil	20,28	
				Medijan	23,13	
				Srednja vrijednost	23,98	
				Treći kvartil	28,51	
				Maksimum	30,40	
				NA	423	
14.	Specifična godišnja potrebna toplinska energija za grijanje nestambene zgrade, $Q'_{H,nd,ref}$ [kWh/m³a]	$Q'_{H,nd,ref}$	2192	Minimum	15,04	kontinuirana
				Prvi kvartil	23,71	
				Medijan	32,80	
				Srednja vrijednost	37,81	
				Treći kvartil	44,59	
				Maksimum	241,20	
				NA	1844	
15.	Relativna vrijednost godišnje potrebne toplinske energije za grijanje za nestambene zgrade, $Q'_{H,nd,rel}$ [%]	$Q'_{H, nd, rel}$	2192	Minimum	15,10	kontinuirana
				Prvi kvartil	98,07	
				Medijan	138,79	
				Srednja vrijednost	154,92	
				Treći kvartil	195,55	
				Maksimum	955,17	
				NA	1793	
16.	Godišnja potrebna toplinska energija za grijanje $Q_{H,nd,ref}$, [kWh/a]	God_eng_grij	2192	Minimum	3002,00	kontinuirana
				Prvi kvartil	58337,00	
				Medijan	131738,00	
				Srednja vrijednost	233866,00	
				Treći kvartil	281850,00	
				Maksimum	4650534,00	
				NA:	1613	
17.	Udio ploštine prozora u ukupnoj ploštini pročelja, f	Udio_pl_proz	2192	Minimum	0,01	kontinuirana
				Prvi kvartil	0,15	
				Medijan	0,21	
				Srednja vrijednost	0,23	
				Treći kvartil	0,26	

				Maksimum	1,00	
18.	Propisana interna temp. u sezoni grijanja	Prop_temp_gri	2192	Minimum	18,00	kontinuirana
				Prvi kvartil	20,00	
				Medijan	20,00	
				Srednja vrijednost	20,33	
				Treći kvartil	20,00	
				Maksimum	22,00	
19.	Propisana interna temp. u sezoni hlađenja	Prop_temp_hla	2192	Minimum	22,00	kontinuirana
				Prvi kvartil	22,00	
				Medijan	22,00	
				Srednja vrijednost	22,51	
				Treći kvartil	24,00	
				Maksimum	24,00	
20.	Ukupna ploština neto hlađene površine zgrade, A_{kh} [m²]	Uk_plo_hla	2192	Minimum	15,60	kontinuirana
				Prvi kvartil	435,70	
				Medijan	1143,70	
				Srednja vrijednost	1689,20	
				Treći kvartil	1410,20	
				Maksimum	58880,00	
21.	Bruto obujam hlađenog dijela zgrade kojem je oplošje A [m³]	Bruto_obujam_hla	2192	Minimum	31,58	kontinuirana
				Prvi kvartil	1385,55	
				Medijan	3643,17	
				Srednja vrijednost	5410,60	
				Treći kvartil	4486,72	
				Maksimum	184000,00	
22.	Ukupna instalirana toplinska snaga dizalice topline [kW]	Uk_topl_diz	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	564,80	
				Treći kvartil	0,00	
				Maksimum	1234343,00	
23.	Ukupan broj ogrjevnih tijela - radijatora	Uk_br_rad	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	41,07	
				Treći kvartil	39,00	
				Maksimum	4153,00	
24.	Ukupno instalirana snaga ogrjevnih tijela - radijatora [kW]	Uk_sng_rad	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	42,80	
				Srednja vrijednost	430,30	
				Treći kvartil	162,50	
				Maksimum	599199,00	
25.	Ukupno instalirana snaga ostalih ogrjevnih tijela [kW]	Uk_sng_ost	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	290,35	
				Treći kvartil	38,95	
				Maksimum	207754,00	
26.	Ukupna instalirana toplinska snaga ogrjevnih tijela [kW]	Uk_sng_ogrj	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	24,30	
				Medijan	86,20	
				Srednja vrijednost	732,80	
				Treći kvartil	249,30	
				Maksimum	599119,00	
27.	Ukupna toplinska snaga [kW]	Uk_top_sng	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	8,00	

				Srednja vrijednost	913,80	
				Treći kvartil	225,00	
				Maksimum	1234343,00	
28.	Ukupna instalirana rashladna snaga rashladnih tijela [kW]	Uk_ras_rash_tj	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	72,65	
				Treći kvartil	9,21	
				Maksimum	56494,00	
29.	Ukupna instalirana rashladna snaga split sustava [kW]	Uk_ras_sng_split	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	16,70	
				Treći kvartil	10,00	
				Maksimum	1830,90	
30.	Ukupna instalirana električna snaga split sustava [kW]	Uk_el_sng_split	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	6,86	
				Treći kvartil	4,59	
				Maksimum	418,55	
31.	Broj instaliranih split sustava	Br_inst_split	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	4,49	
				Treći kvartil	3,00	
				Maksimum	288,00	
32.	Ukupna instalirana rashladna snaga sustava [kW]	Uk_ras_sng_sus	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	27,75	
				Treći kvartil	12,5	
				Maksimum	4628,50	
33.	Ukupna instalirana toplinska snaga sustava PTV [kW]	Uk_inst_top_PTV	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	38,48	
				Treći kvartil	0,00	
				Maksimum	25000,00	
34.	Ukupna instalirana električna snaga sustava PTV [kW]	Uk_el_PTV	2192	Minimum	0,00	Kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	4,68	
				Treći kvartil	4,00	
				Maksimum	1267,00	
35.	Volumen spremnika PTV (električni bojleri) [l]	Vol_PTV	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	39,33	
				Treći kvartil	0,00	
				Maksimum	10000,00	
36.	Ukupna instalirana snaga žarulja sa žarnom niti [kW]	Uk_sng_žnit	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,24	
				Srednja vrijednost	22,51	
				Treći kvartil	1,92	
				Maksimum	29185,00	

37.	Ukupni broj svjetiljki sa žaruljama sa žarnom niti	Uk_br_žniti	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	30,43	
				Treći kvartil	22,00	
				Maksimum	2951,00	
38.	Ukupna instalirana snaga fluokompaktnih žarulja [kW]	Uk_sng_flou_žar	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	11,63	
				Treći kvartil	0,00	
				Maksimum	22958,00	
39.	Ukupni broj svjetiljki s fluokompaktnim žaruljama	Uk_br_flou_žar	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	23,86	
				Treći kvartil	0,00	
				Maksimum	4300,00	
40.	Ukupna instalirana snaga fluorescentnih cijevi s elektromag.prigušnicom [kW]	Uk_sng_flou_cj	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,50	
				Srednja vrijednost	67,38	
				Treći kvartil	8,21	
				Maksimum	43893,00	
41.	Ukupni broj svjetiljki s fluorescentnim cijevima s elektromag. prigušnicom	Uk_br_flou_cj	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	148,70	
				Treći kvartil	134,20	
				Maksimum	8995,00	
42.	Ukupna instalirana snaga unutarnje rasvjete [kW]	Uk_sng_un_ras	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	3,02	
				Srednja vrijednost	118,02	
				Treći kvartil	17,16	
				Maksimum	57250,60	
43.	Ukupni broj svjetiljki unutarnje rasvjete	Uk_br_un_ras	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	20,00	
				Srednja vrijednost	253,60	
				Treći kvartil	241,20	
				Maksimum	53464,02	
44.	Ukupna instalirana električna snaga uredske opreme [kW]	Uk_inst_sng_uo	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	21,25	
				Treći kvartil	10,32	
				Maksimum	12775,00	
45.	Ukupna instalirana električna snaga kuhinjske opreme [kW]	Uk_inst_el_kuh	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	15,47	
				Treći kvartil	6,50	
				Maksimum	6947,00	
46.	Ukupna instalirana električna snaga ostalih potrošača [kW]	Uk_inst_el_op	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	23,14	

				Treći kvartil	5,00	
				Maksimum	10239,00	
47.	Ukupna instalirana snaga ostalih sustava [kW]	Uk_inst_sus	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	4,36	
				Srednja vrijednost	59,84	
				Treći kvartil	32,10	
				Maksimum	17637,00	
48.	Hlađeno oplošje	Hla_opl	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	397,00	
				Treći kvartil	105,10	
				Maksimum	60000,00	
49.	Hlađeni volumen	Hla_vol	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	943,30	
				Treći kvartil	214,40	
				Maksimum	184000,00	
50.	Koeficijent prolaska topline građevnih dijelova, U [W/m²K] - krov	Koef_prol_topl_krov	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	0,37	
				Treći kvartil	0,00	
				Maksimum	260,00	
51.	Koeficijent prolaska topline građevnih dijelova, U [W/m²K] - poda	Koef_prol_topl_pod	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	0,43	
				Treći kvartil	0,00	
				Maksimum	22,00	
52.	Debljina građevnog dijela [cm] - poda	Deb_građ_pod	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	12,26	
				Treći kvartil	23,00	
				Maksimum	140,00	
53.	Debljina građevnog dijela [cm] - prozori	Deb_građ_proz	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	2,85	
				Treći kvartil	5,50	
				Maksimum	52,00	
54.	Koeficijent prolaska topline građevnih dijelova, U [W/m²K] –vanjski zid	Koef_prol_topl_vzid	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	2,24	
				Treći kvartil	0,36	
				Maksimum	1495,79	
55.	Ploština građevnog dijela [m²] – vanjski zid	Plo_građ_dijela_vzid	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	218,30	
				Treći kvartil	0,00	
				Maksimum	27391,00	
56.		Deb_građ_vzid	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	30,00	

	Debljina građevnog dijela [cm] – vanjski zid			Medijan	38,00	
				Srednja vrijednost	36,74	
				Treći kvartil	47,00	
				Maksimum	455,00	
57.	Debljina građevnog dijela [cm] -vrata	Deb_građ_vrata	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	2,20	
				Treći kvartil	5,00	
				Maksimum	35,00	
58.	Debljina građevnog dijela [cm] –negrijani zid	Deb_građ_nzid	2192	Minimum	0,00	kontinuirana
				Prvi kvartil	0,00	
				Medijan	0,00	
				Srednja vrijednost	7,54	
				Treći kvartil	0,00	
				Maksimum	110,00	
59.	Broj zaposlenih	Br_zap		Minimum	1,00	kontinuirana
				Prvi kvartil	9,00	
				Medijan	30,00	
				Srednja vrijednost	57,53	
				Treći kvartil	61,00	
				Maksimum	1996,00	
60.	Broj korisnika	Br_kor	2192	Minimum	1,00	kontinuirana
				Prvi kvartil	51,00	
				Medijan	170,00	
				Srednja vrijednost	923,60	
				Treći kvartil	491,50	
				Maksimum	840576,00	
61.	Prosječna trogodišnja potrošnja energije izražena u kWh	Prosj_pot_eng	2192	Minimum	13635,00	kontinuirana
				Prvi kvartil	35565,00	
				Medijan	114016,00	
				Srednja vrijednost	277846,00	
				Treći kvartil	288785,00	
				Maksimum	13416224,00	
62.	Prosječna trogodišnja potrošnja energije $[kWH/m^2]$	Prosj_pot_en_m2	2192	Minimum	14,08	kontinuirana
				Prvi kvartil	94,70	
				Medijan	141,54	
				Srednja vrijednost	166,28	
				Treći kvartil	204,09	
				Maksimum	2391,30	
63.	Prosječan trogodišnji trošak energije izražen u kn	Proj_troš_en	2192	Minimum	1254,00	kontinuirana
				Prvi kvartil	17585,00	
				Medijan	61939,00	
				Srednja vrijednost	144711,00	
				Treći kvartil	145959,00	
				Maksimum	7613209,00	
64.	Regija	Regija	2192	Kontinentalna Hrvatska	1596,00	kategorijalna
				Primorska Hrvatska:	596,00	
65.	Namjena zgrade	Namjena	2192	Zdravstvene ustanove	151,00	kategorijalna
				Obrazovne ustanove	1318,00	
				Uredske zgrade	510,00	

				Zgrade socijalne namjene	109,00	
				Zgrade s namjenom u kulturi	49,00	
				Vojni objekti	17,00	
				Zgrade opće namjene	38,00	
66.	Kulturno dobro	Kul_dobro	2192	Zgrada je dio kulturne baštine	285,00	kategorijalna
				Zgrada nije dio kulturne baštine	1934,00	
67.	Razdoblje izgradnje	Razd_izgr	2192	<1919	461,00	kategorijalna
				1919.-1945.	187,00	
				1946.-1970.	518,00	
				1971.-1980.	317,00	
				1981.-1990.	218,00	
				1991.-2000.	133,00	
				>2000.	358,00	
68.	Tip objekta	Tip_obj	2192	Kompleks zgrada	96,00	kategorijalna
				Dio zgrade	292,00	
				Zgrada	1804,00	
69.	Razdoblje posljednje rekonstrukcije	Raz_rekon	2192	Prije 2012	2075,00	kategorijalna
				Nakon 2012	117,00	

Izvor: Izrada autora

Prilog 2 – *Tablica 29 Odabir varijabli za Model 1, Model 2, Model 3*

Tablica 29 Odabir varijabli za Model 1, Model 2, Model 3

Rb	Naziv varijable	Šifra varijable	N	Tip varijable	Model 1	Model 2 FSelector (DA/NE)	Model 3 Boruta (DA/NE)
1.	Udio u ukupnoj površini zgrade [%]	Udio_uk_po	2192	kontinuirana	DA	NE	NE
2.	Ukupna ploština neto podne površine grijanog dijela zgrade	Uk_plo_net	2192	kontinuirana	DA	NE	DA
3.	Broj radnih dana u tjednu	Br_dn_tj	2192	kontinuirana	**DA**	**DA**	**DA**
4.	Broj radnih sati u danu	Br_rs_tj	2192	kontinuirana	**DA**	**DA**	**DA**
5.	Ploština bruto podne površine zgrade [m²]	Pl_br_pod	2192	kontinuirana	DA	NE	DA
6.	Oplošje grijanog dijela zgrade A [m²]	Op_grij_zg	2192	kontinuirana	DA	NE	DA
7.	Bruto obujam grijanog dijela zgrade kojem je oplošje A [m³]	Br_obuj_grij	2192	kontinuirana	DA	NE	DA
8.	Broj etaža	Br_et	2192	kontinuirana	DA	NE	DA
9.	Unutarnja projektna temperatura u sezoni grijanja [°C]	Un_temp_gri	2192	kontinuirana	DA	NE	DA
10.	Temperatura na mjernoj stanici	Temp_mjer_st	2192	kontinuirana	**DA**	**DA**	**DA**
11.	Faktor oblika zgrade, F0 [m?1]	F_o	2192	kontinuirana	DA	NE	DA
12.	Koeficijent transmisijskog. topl. gubitka po jed. oplošja grij. dijela zgrade H'tr,iz [W/m²K]	Koef_trans	2192	kontinuirana	DA	DA	DA
13.	Udio ploštine prozora u ukupnoj ploštini pročelja, f	Udio_pl_proz	2192	kontinuirana	DA	NE	NE
14.	Propisana interna temp. u sezoni grijanja	Prop_temp_gri	2192	kontinuirana	DA	DA	DA

15.	Propisana interna temp. u sezoni hlađenja	Prop_temp_hla	2192	kontinuirana	DA	DA	DA
16.	Ukupna ploština neto hlađene površine zgrade, A_{kh} [m²]	Uk_plo_hla	2192	kontinuirana	DA	NE	NE
17.	Bruto obujam hlađenog dijela zgrade kojem je oplošje A [m³]	Bruto_obujam_hla	2192	kontinuirana	DA	NE	NE
18.	Ukupna instalirana toplinska snaga dizalice topline [kW]	Uk_topl_diz	2192	kontinuirana	DA	NE	DA
19.	Ukupan broj ogrjevnih tijela - radijatora	Uk_br_rad	2192	kontinuirana	DA	DA	DA
20.	Ukupno instalirana snaga ogrjevnih tijela - radijatora [kW]	Uk_sng_rad	2192	kontinuirana	DA	DA	DA
21.	Ukupno instalirana snaga ostalih ogrjevnih tijela [kW]	Uk_sng_ost	2192	kontinuirana	DA	NE	DA
22.	Ukupna instalirana toplinska snaga ogrjevnih tijela [kW]	Uk_sng_ogrj	2192	kontinuirana	DA	NE	DA
23.	Ukupna toplinska snaga [kW]	Uk_top_sng	2192	kontinuirana	DA	DA	DA
24.	Ukupna instalirana rashladna snaga rashladnih tijela [kW]	Uk_ras_rash_tj	2192	kontinuirana	DA	NE	DA
25.	Ukupna instalirana rashladna snaga split sustava [kW]	Uk_ras_sng_split	2192	kontinuirana	DA	DA	DA
26.	Ukupna instalirana električna snaga split sustava [kW]	Uk_el_sng_split	2192	kontinuirana	DA	DA	DA
27.	Broj instaliranih split sustava	Br_inst_split	2192	kontinuirana	DA	NE	DA
28.	Ukupna instalirana rashladna snaga sustava [kW]	Uk_ras_sng_sus	2192	kontinuirana	DA	DA	DA

29.	Ukupna instalirana toplinska snaga sustava PTV [kW]	Uk_inst_top_PTV	2192	kontinuirana	DA	DA	DA
30.	Ukupna instalirana električna snaga sustava PTV [kW]	Uk_el_PTV	2192	kontinuirana	DA	DA	DA
31.	Volumen spremnika PTV (električni bojleri) [l]	Vol_PTV	2192	kontinuirana	DA	DA	NE
32.	Ukupna instalirana snaga žarulja sa žarnom niti [kW]	Uk_sng_žnit	2192	kontinuirana	DA	DA	DA
33.	Ukupni broj svjetiljki sa žaruljama sa žarnom niti	Uk_br_žniti	2192	kontinuirana	DA	NE	DA
34.	Ukupna instalirana snaga fluokompaktnih žarulja [kW]	Uk_sng_flou_žar	2192	kontinuirana	DA	NE	NE
35.	Ukupni broj svjetiljki s fluokompaktnim žaruljama	Uk_br_flou_žar	2192	kontinuirana	DA	NE	DA
36.	Ukupna instalirana snaga fluorescentnih cijevi s elektromag.prigušnicom [kW]	Uk_sng_flou_cj	2192	kontinuirana	DA	NE	DA
37.	Ukupni broj svjetiljki s fluorescentnim cijevima s elektromag. prigušnicom	Uk_br_flou_cj	2192	kontinuirana	DA	DA	DA
38.	Ukupni broj svjetiljki unutarnje rasvjete	Uk_br_un_ras	2192	kontinuirana	DA	NE	NE
39.	Ukupna instalirana snaga unutarnje rasvjete [kW]	Uk_sng_un_ras	2192	kontinuirana	DA	NE	DA
40.	Ukupna instalirana električna snaga uredske opreme [kW]	Uk_inst_sng_uo	2192	kontinuirana	DA	DA	DA

41.	Ukupna instalirana električna snaga kuhinjske opreme [kW]	Uk_inst_el_kuh	2192	kontinuirana	DA	DA	DA
42.	Ukupna instalirana električna snaga ostalih potrošača [kW]	Uk_inst_el_op	2192	kontinuirana	DA	DA	DA
43.	Ukupna instalirana snaga ostalih sustava [kW]	Uk_inst_sus	2192	kontinuirana	DA	NE	DA
44.	Hlađeno oplošje	Hla_opl	2192	kontinuirana	DA	NE	NE
45.	Hlađeni volumen	Hla_vol	2192	kontinuirana	DA	NE	DA
46.	Koeficijent prolaska topline građevnih dijelova, U [W/m²K] - krov	Koef_prol_topl_krov	2192	kontinuirana	DA	NE	NE
47.	Koeficijent prolaska topline građevnih dijelova, U [W/m²K] - poda	Koef_prol_topl_pod	2192	kontinuirana	DA	DA	NE
48.	Debljina građevnog dijela [cm] - poda	Deb_građ_pod	2192	kontinuirana	DA	NE	NE
49.	Debljina građevnog dijela [cm] - prozori	Deb_građ_proz	2192	kontinuirana	DA	NE	NE
50.	Koeficijent prolaska topline građevnih dijelova, U [W/m²K] – vanjski zid	Koef_prol_topl_vzid	2192	kontinuirana	DA	NE	NE
51.	Ploština građevnog dijela [m^2] – vanjski zid	Plo_građ_dijela_vzid	2192	kontinuirana	DA	DA	DA
52.	Debljina građevnog dijela [cm] – vanjski zid	Deb_građ_vzid	2192	kontinuirana	DA	NE	NE
53.	Debljina građevnog dijela [cm] - vrata	Deb_građ_vrata	2192	kontinuirana	DA	NE	NE
54.	Debljina građevnog dijela [cm] – negrijani zid	Deb_građ_nzid	2192	kontinuirana	DA	NE	NE

55.	Broj zaposlenih	Br_zap	2192	kontinuirana	DA	NE	DA
56.	Broj korisnika	Br_kor	2192	kontinuirana	DA	NE	DA
57.	Regija	Regija	2192	kategorijalna	DA	DA	DA
58.	Namjena zgrade	Namjena	2192	kategorijalna	DA	DA	DA
59.	Kulturno dobro	Kul_dobro	2192	kategorijalna	DA	NE	NE
60.	Razdoblje izgradnje	Razd_izgr	2192	kategorijalna	DA	NE	NE
61.	Tip objekta	Tip_obj	2192	kategorijalna	DA	DA	NE
62.	Razdoblje posljednje rekonstrukcije	Raz_rekon	2192	kategorijalna	DA	NE	NE
63.	Klasa zgrade javnog sektora prema stvarnoj potrošnji energije	Klasa	2192	kategorijalna	**Ciljna varijabla**		

Izvor: Izrada autora