Modeli procjene troškova toplinske energije školskih zgrada na području Federacije Bosne i Hercegovine

Katić, Dragan

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Civil Engineering and Architecture Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski i arhitektonski fakultet Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:133:490010

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

GRAĐEVINSKI I ARHITEKTONSKI FAKULTET OSIJEK
Faculty of Civil Engineering and Architecture Osijek

Repository / Repozitorij:

Repository GrAFOS - Repository of Faculty of Civil Engineering and Architecture Osijek

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište Josipa Jurja Strossmayera u Osijeku

Građevinski i arhitektonski fakultet Osijek

Poslijediplomski sveučilišni studij Građevinarstvo

Doktorska disertacija

Modeli procjene troškova toplinske energije školskih zgrada na području Federacije Bosne i Hercegovine

Mr. sc. Dragan Katić, dipl. ing. građ.

Osijek, 2022. godine

Doktorsku disertaciju posvećujem

supruzi Danijeli i djeci Jakovu, Petri, Ani i Josipu.

Josip Juraj Strossmayer University of Osijek

Faculty of Civil Engineering and Architecture Osijek

Postgraduate University Study Programme in Civil Engineering

Doctoral dissertation

Models for estimating the heating energy costs of school buildings in the Federation of Bosnia and Herzegovina

Dragan Katić, M.Sc. in Civ. Eng.

Osijek, 2022

PROSUDBENA POVJERENSTVA I BIBLIOGRAFSKI PODATCI

Povjerenstvo za prihvaćanje teme doktorske disertacije

Povjerenstvo za prihvaćanje teme doktorske disertacije imenovano je na 8. redovitoj elektroničkoj sjednici Fakultetskog vijeća Građevinskog i arhitektonskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku, održanoj 15. srpnja 2021. godine:

1. *Prof. dr. sc. Zlata Dolaček-Alduk, dipl. ing. građ., Građevinski i arhitektonski fakultet Osijek, predsjednica*
2. *Izv. prof. dr. sc. Hrvoje Krstić, dipl. ing. građ., Građevinski i arhitektonski fakultet Osijek, član*
3. *Izv. prof. dr. sc. Ivana Domljan, dipl. ing. građ., Sveučilište u Mostaru, Građevinski fakultet, Bosna i Hercegovina, članica*

Tema i mentor doktorske disertacije prihvaćeni su odlukom Fakultetskog vijeća Građevinskog i arhitektonskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku, na 14. redovitoj sjednici održanoj 15. rujna 2021. godine.

Povjerenstvo za ocjenu doktorske disertacije

Povjerenstvo za ocjenu doktorske disertacije imenovano je na 4. redovitoj sjednici Fakultetskog vijeća Građevinskog i arhitektonskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku, održanoj 12. siječnja 2022. godine:

1. *Prof. dr. sc. Zlata Dolaček-Alduk, dipl. ing. građ., Građevinski i arhitektonski fakultet Osijek, predsjednica*
2. *Izv. prof. dr. sc., Hrvoje Krstić, dipl. ing. građ., Građevinski i arhitektonski fakultet Osijek, član i mentor*
3. *Izv. prof. dr. sc. Ivana Domljan, dipl. ing. građ., Sveučilište u Mostaru, Građevinski fakultet, Bosna i Hercegovina, članica*

Doktorska disertacija prihvaćena je odlukom Fakultetskog vijeća Građevinskog i arhitektonskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku, na 6. redovitoj sjednici održanoj 9. ožujka 2022. godine.

Povjerenstvo za obranu doktorske disertacije

Povjerenstvo za obranu doktorske disertacije imenovano je na 6. redovitoj sjednici Fakultetskog vijeća Građevinskog i arhitektonskog fakulteta Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku, održanoj 9. ožujka 2022. godine:

1. *Prof. dr. sc. Zlata Dolaček-Alduk, dipl. ing. građ., Građevinski i arhitektonski fakultet Osijek, predsjednica*
2. *Izv. prof. dr. sc. Hrvoje Krstić, dipl. ing. građ., Građevinski i arhitektonski fakultet Osijek, mentor i član*
3. *Izv. prof. dr. sc. Ivana Domljan, dipl. ing. građ., Sveučilište u Mostaru, Fakultet građevinarstva, arhitekture i geodezije, Bosna i Hercegovina, članica*
4. *Doc. dr. sc. Mario Galić, dipl. ing. građ., Građevinski i arhitektonski fakultet Osijek, zamjenski član*

Doktorska disertacija javno je obranjena 25. ožujka 2022. godine na Građevinskom i arhitektonskom fakultetu Osijek Sveučilišta Josipa Jurja Strossmayera u Osijeku.

Doktorska disertacija sadržava *247 stranica, 43 ilustracije, 49 tablica, 2 dodatka i 145 citiranih publikacija.*

Mentor doktorske disertacije je *izv. prof. dr. sc. Hrvoje Krstić, dipl. ing. građ., Građevinski i arhitektonski fakultet Osijek.*

Istraživanje u okviru doktorske disertacije pripada znanstvenom području tehničkih znanosti, znanstvenom polju građevinarstvo.

Izjava o akademskoj čestitosti

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

Izjavljujem kako nisam prijavio doktorsku disertaciju s istovjetnom temom na drugom studiju Sveučilišta ili na drugom sveučilištu.

Osijek, 5.1.2022. godine

Dragan Katić

Predgovor

Aktualni trendovi u građevinarstvu su usmjereni na održivu gradnju, energetsku učinkovitost, smanjenje negativnog utjecaja građevina na okoliš i smanjenje potrošnje ukupne energije u svim fazama životnog ciklusa projekta od planiranja i građenja, preko najduže faze uporabe i održavanja do faze uklanjanja građevine. Tijekom faze uporabe troši se energija za grijanje, hlađenje, osvjetljavanje i pokretanje opreme i uređaja i nastaju troškovi vezani za potrošnju energije koji predstavljaju jedan dio troškova životnog ciklusa zgrada. Troškovi uporabe energije zgrada direktno su vezani s količinom potrošene energije koja ovisi o tehničkim karakteristikama zgrade, instaliranim uređajima i opremi te ponašanju korisnika. Dosadašnja istraživanja o troškovima životnog ciklusa zgrada pokazala su kako su troškovi životnog ciklusa dobro razrađeni u teoriji, ali pri primjeni nastaju poteškoće prvenstveno zbog nedostatka korisnih, pouzdanih i konzistentnih podataka potrebnih za procjenu ukupnih troškova životnog ciklusa zgrada. Također, uočava se nedostatak empirijskih istraživanja koja povezuju karakteristike zgrade s troškovima životnog ciklusa.

U Federaciji Bosne i Hercegovine (FBiH) od 2010. godine pokrenuti su projekti povećanja energetske učinkovitosti javnih zgrada, posebno zgrada namijenjenih za obrazovanje, koji su bazirani na analizi potrošnje energije i mjerama za poboljšanje energetske učinkovitosti koje se definiraju u dokumentima detaljnih energetskih pregleda. Dokumenti detaljnih energetskih pregleda su izrađeni prema propisanim uputama i smjernicama te sadrže veliku količinu podataka o karakteristikama zgrada, potrošnji i troškovima toplinske energije te se isti podatci mogu smatrati validnim, pouzdanim i reprezentativnim.

Stoga je ovo istraživanje usmjereno na prikupljanje i analizu podataka o energetskim karakteristikama, potrošnji i troškovima toplinske energije školskih zgrada u FBiH kao jednom značajnom dijelu troškova životnog ciklusa zgrada. Svrha ovog istraživanja je određivanje povezanosti energetskih karakteristika (performansi) školskih zgrada u FBiH s troškovima toplinske energije kroz razvoj novih regresijskih modela koji omogućavaju jednostavniju i bržu procjenu troškova toplinske energije i koji se mogu koristiti u inženjerskoj praksi.

Ovim putem zahvaljujem Fondu za zaštitu okoliša FBiH koji je ustupio dokumente detaljnih energetskih pregleda školskih zgrada u FBiH i koji su predstavljali bazu za prikupljanje podataka neophodnih za provedbu ovog istraživanja.

Posebno se zahvaljujem studijskom savjetniku i mentoru izv. prof. dr. sc. Hrvoju Krstiću za nesebičnu pomoć i doprinos u izradi ove doktorske disertacije.

Sažetak

Pregled istraživanja o troškovima životnog ciklusa zgrada pokazuju nedostatak istraživanja koja povezuju karakteristike zgrade s troškovima životnog ciklusa. Posebno se naglašava nedostatak korisnih, pouzdanih i konzistentnih podataka potrebnih za procjenu ukupnih troškova životnog ciklusa zgrada. Opći ciljevi ovog istraživanja jesu prikupljanje i analiza podataka o energetskim karakteristikama, potrošnji i troškovima toplinske energije školskih zgrada u Federaciji Bosne i Hercegovine kako bi se istražio utjecaj pojedinih karakteristika (varijabli) zgrada na troškove toplinske energije. Posebni cilj ovog istraživanja jeste razvoj novih matematičkih modela za bržu i jednostavniju procjenu troškova toplinske energije školskih zgrada koji će se temeljiti na karakteristikama školskih zgrada u FBiH.

Za ovo istraživanje korišteni su podatci iz dokumenata detaljnih energetskih pregleda školskih zgrada u FBiH koji sadrže veliku količinu podataka o energetskim karakteristikama, potrošnji i troškovima toplinske energije. U prvom koraku provedena je statistička analiza energetskih karakteristika školskih zgrada u FBiH u odnosu na razdoblje izgradnje na temelju prikupljenih podataka iz uzorka. Usporedbom stvarne i proračunske potrošnje toplinske energije za grijanje utvrđeno je da stvarna potrošnja iznosi prosječno oko 65 % potrebne. Navedeni zaključak je jako bitan jer stvarna potrošnja toplinske energije ne odražava potrebe te su se u razvoju matematičkih modela procjene troškova toplinske energije koristile proračunske vrijednosti potrošnje toplinske energije. U drugom koraku provedena je analiza neovisnih varijabli i provedeno je razdvajanje osnovnog seta podataka na set za razvoj i set koji služi za validaciju regresijskih modela. Najčešći statistički modeli za procjenu energetskih karakteristika zgrada su regresijski modeli koji povezuju potrošnju i troškove energije s jednom ili više varijabli. Postupkom postupne regresijske metode unaprijed razvijeni su višestruki linearni regresijski modeli, a za ocjenu istih korištene su neke od statističkih metoda. Za ocjenu i rangiranje razvijenih regresijskih modela korišteni su kriterij reprezentativnosti i kriterij jednostavnosti. Razvijenim regresijskim potvrđena je hipoteza ovog istraživanja da se neovisnim varijablama ili karakteristikama školskih zgrada mogu procijeniti ovisne varijable, odnosno troškovi toplinske energije školskih zgrada u FBiH.

Ključne riječi

energetske karakteristike (performanse) zgrada, troškovi životnog ciklusa zgrada, toplinska energija, troškovi toplinske energije, statistička analiza, regresijski modeli

Autor: Mr. sc. Dragan Katić, dipl. ing. građ.

Mentor: Izv. prof. dr. sc. Hrvoje Krstić, dipl. ing. građ.

Abstract

A review of research on the life cycle costs of buildings shows a lack of empirical research linking building characteristics to life cycle costs. Particular emphasis is placed on the lack of useful, reliable and consistent data needed to estimate the total life cycle costs of buildings. The general objectives of this research are to collect and analyze data on energy performance, energy consumption for space heating and heating energy costs of school buildings in the Federation of Bosnia and Herzegovina (FBiH) to investigate the impact of individual characteristics (variables) of buildings on heating energy costs. The special goal of this research is to develop new mathematical models for faster and simpler estimation of heating energy costs of school buildings, which will be based on the energy performance of school buildings in FBiH.

For this research, data from the documents of detailed energy audits of school buildings in the FBiH were used, which contain a large amount of data on energy characteristics, energy consumption for space heating and heating energy costs. In the first step, a statistical analysis of the energy performance of school buildings in the FBiH in relation to construction periods was performed based on the data collected from the sample. By comparing the actual (measured) and predicted (calculated) delivered energy for space heating, it was determined that the actual consumption is on average about 65% of the predicted. This conclusion is very important because the actual energy consumption for space heating does not reflect the needs, and in the development of mathematical models for estimating the heating energy costs, the calculated values of energy for space heating were used. In the second step, the analysis of independent variables was performed and the separation of the basic data set into the training set and the set used for the validation of regression models was performed. The most common statistical models for estimating the energy performance of buildings are regression models that link energy consumption and heating energy costs to one or more variables. Multiple linear regression models have been developed in advance using the stepwise regression method, and some of the statistical methods have been used to estimate them. The criterion of representativeness and the criterion of simplicity were set for the evaluation and ranking of the developed regression models. The developed regression models confirmed the hypothesis of this research that independent variables or performance of school buildings can be used to estimate dependent variables, ie the heating energy costs of school buildings in the FBiH.

Key words

energy performance of buildings, life cycle costs of buildings, energy consumption for space heating, heating energy costs, statistical analysis, regression models

Author: Dragan Katić, M.Sc. in Civ. Eng.

Mentor: Hrvoje Krstić, Ph.D. in Civ. Eng.

Sadržaj

Popis ilustracija.....XV

Popis tablica.....XVIII

Popis kratica i simbola.....XXII

Popis engleskih izraza i kratica.....XXV

1. Uvod..... 1

1.1 Obrazloženje teme 1

1.2 Svrha i ciljevi istraživanja..... 6

1.3 Metode istraživanja i definiranje hipoteza istraživanja 9

1.4 Struktura rada i očekivani znanstveni doprinos 12

2. Pregled dosadašnjih istraživanja vezanih za troškove uporabe i održavanja zgrada 15

2.1 Uvod u troškove uporabe i održavanja zgrada..... 15

2.2 Dosadašnja istraživanja o troškovima uporabe i održavanja zgrada 16

2.3 Životni ciklus zgrade 18

2.4 Struktura troškova održavanja i uporabe zgrada 20

2.4.1 Ukupni troškovi životnog ciklusa..... 20

2.4.2 Troškovi životnog ciklusa zgrada 23

2.5 Matematički modeli za proračun troškova životnog ciklusa 33

2.6 Pregled udjela pojedinih troškova životnog ciklusa 39

2.7 Pregled potrošnje toplinske energije 43

2.8 Zaključna razmatranja o troškovima životnog ciklusa..... 46

3. Prikupljanje i obrada podataka..... 49

3.1 Pregled stanja i zakonodavnog okvira u BiH 49

3.2 Podatci o karakteristikama javnih zgrada namijenjenih za obrazovanje u Federaciji Bosne i Hercegovine 52

3.3 Prikupljanje i obrada podataka o karakteristikama školskih zgrada u FBiH..... 62

4. Statistička analiza prikupljenih podataka o energetskim karakteristikama školskih zgrada u FBiH iz uzorka ... 71

4.1 Statistički uzorak ... 71

4.2 Analiza karakteristika školskih zgrada u FBiH iz uzorka ... 76

4.2.1 Analiza općih i geometrijskih karakteristika školskih zgrada u FBiH iz uzorka ... 77

4.2.2 Analiza karakteristika građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka 83

4.3 Analiza potrošnje energije školskih zgrada u FBiH iz uzorka ... 97

4.3.1 Analiza stvarne potrošnje toplinske i električne energije školskih zgrada u FBiH iz uzorka ... 97

4.3.2 Analiza proračunske potrošnje toplinske energije školskih zgrada u FBiH iz uzorka ... 101

4.4 Analiza troškova potrošnje energije školskih zgrada u FBiH iz uzorka ... 114

4.5 Zaključna razmatranja o potrošnji i troškovima energije školskih zgrada u FBiH iz uzorka 126

5. Izrada i validacija modela procjene troškova toplinske energije školskih zgrada u FBiH ... 131

5.1 Definiranje hipoteze istraživanja ... 131

5.2 Izbor mogućih varijabli ... 131

5.3 Određivanje seta podataka za razvoj i validaciju regresijskih modela ... 140

5.4 Korelacijska analiza ... 145

5.5 Metode za validaciju regresijskih modela ... 148

5.6 Razvoj regresijskih modela procjene troškova toplinske energije školskih zgrada u FBiH . 155

5.7 Validacija regresijskih modela procjene troškova toplinske energije školskih zgrada u FBiH na setu za razvoj i validaciju ... 165

5.8 Analiza modela procjene ukupnih proračunskih troškova isporučene toplinske energije školskih zgrada u FBiH ... 179

5.9 Analiza neovisnih varijabli u regresijskim modelima ... 183

5.10 Zaključna razmatranja o modelima procjene proračunskih troškova isporučene toplinske energije školskih zgrada u FBiH ... 187

6. Zaključak i smjernice za daljnja istraživanja ... 191

6.1 Zaključak ... 191

6.2 Smjernice za daljnja istraživanja ... 197

Literatura 199

Prilozi 207

Prilog 1 – Ulazni podatci o karakteristikama školskih zgrada u FBiH iz uzorka……208

Prilog 2 – Korelacijska analiza neovisnih i ovisnih varijabli ulaznog seta podataka školskih zgrada u FBiH iz uzorka……213

Popis ilustracija

Slika 1.1	Procjena energetskih karakteristika zgrade u usporedbi sa statističkim mjerilima	8
Slika 2.1	Ukupni životni ciklus građevine	19
Slika 2.2	Shema ovisnosti smanjenja na troškovima uporabe i održavanja zgrade u odnosu na troškove primjene određenih aktivnosti	20
Slika 2.3	Struktura ukupnih životnih troškova i troškova životnog ciklusa	21
Slika 2.4	Struktura troškova životnog ciklusa	24
Slika 2.5	Struktura kapitalnih troškova	24
Slika 2.6	Struktura budućih troškova zgrade	30
Slika 2.7	Podatci potrebni za analizu troškova životnog ciklusa	39
Slika 3.1	Struktura potrošnje energije u Bosni i Hercegovini	49
Slika 3.2	Teritorijalna karta Bosne i Hercegovine	50
Slika 4.1	Lokacije školskih zgrada u FBiH iz uzorka	71
Slika 4.2	Raspodjela broja školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije	73
Slika 4.3	Raspodjela ukupne korisne površine (A_k) školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije	74
Slika 4.4	Histogram broja školskih zgrada u FBiH iz uzorka u odnosu na broj stupanj dana grijanja (SDG)	77
Slika 4.5	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na broj korisnika i korisnoj površini (A_k) po korisniku	78
Slika 4.6	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i starost	79
Slika 4.7	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na korisnu površinu A_k i volumen grijanog zraka (V_e)	79
Slika 4.8	Histogram broja školskih zgrada u FBiH iz uzorka u odnosu na površinu ovojnice (A)	80
Slika 4.9	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na faktore oblika (f) i kompaktnosti (f_o)	81
Slika 4.10	Udio pojedinačnih površina građevinskih dijelova u ukupnoj površini ovojnice školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje	85
Slika 4.11	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na površinu zidova, podova, stropova i otvora ovojnice	86
Slika 4.12	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na U - vrijednosti zidova, podova, stropova i otvora ovojnice	88
Slika 4.13	Histogram broja školskih zgrada u FBiH iz uzorka u odnosu na U – vrijednosti ovojnice	89
Slika 4.14	Prosječne U – vrijednosti građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje	90

Slika 4.15	Prosječne vrijednosti i udio (%) koeficijenta transmisijske izmjene topline H_D (W/K), H_G (W/K) i zajednički H_U (W/K) i H_A (W/K) školskih zgrada u FBiH iz uzorka	93
Slika 4.16	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na koeficijente transmisijske i ukupne izmjene topline $H'_{tr,adj}$ (W/m²K) i H' (W/m²K)	95
Slika 4.17	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na specifičnu isporučenu toplinsku energiju za grijanje ($Q'_{H,del}$) i specifičnu isporučenu električnu energiju (E'_{del})	98
Slika 4.18	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na specifičnu isporučenu toplinsku energiju za grijanje ($Q'_{H,del}$) u RS i RJ FBiH	99
Slika 4.19	Shema proračuna potrebne toplinske energije	104
Slika 4.20	Vrijednosti i energetski razredi u FBiH	106
Slika 4.21	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na proračunsku specifičnu potrebnu ($Q'_{H,nd,cal}$) i proračunsku isporučenu godišnju toplinsku energiju ($Q'_{H,del,cal}$) za grijanje	108
Slika 4.22	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na proračunsku specifičnu potrebnu godišnju toplinsku energiju za grijanje ($Q'_{H,nd,cal}$) prema klimatskim regijama u FBiH	109
Slika 4.23	Prosječan odnos (%) stvarne i proračunske isporučene toplinske energije za grijanje ($Q'_{H,del}$) školskih zgrada u FBiH iz uzorka ukupno i prema klimatskim regijama u FBiH	111
Slika 4.24	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na jedinični troška energenata ($UC_{QH,del}$) i specifični godišnji trošak toplinske energije ($C'_{QH,del}$)	117
Slika 4.25	Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na jedinični trošak električne energije ($UC_{E,del}$) i specifični trošak električne energije ($C'_{E,del}$)	118
Slika 4.26	Histogram broja školskih zgrada u FBiH iz uzorka u odnosu na korišteni energent za grijanje	121
Slika 4.27	Prikaz odnosa pojedinačnih vrijednosti prosječnog jediničnog troška energenata za grijanje po utrošenoj isporučenoj energiji u odnosu na prosječnu vrijednost školskih zgrada u FBiH iz uzorka	122
Slika 4.28	Dijagram rasipanja specifične isporučene toplinske energije ($Q'_{H,del}$) u odnosu na godine izgradnje školskih zgrada u FBiH iz uzorka	127
Slika 4.29	Dijagram rasipanja stvarne specifične isporučene toplinske energije ($Q'_{H,del}$) u odnosu na U-vrijednost ovojnice školskih zgrada u FBiH iz uzorka	128
Slika 4.30	Dijagrami rasipanja stvarne specifične isporučene toplinske energije ($Q'_{H,del}$) u odnosu na U-vrijednost ovojnice prema klimatskim regijama RS i RJ školskih zgrada u FBiH iz uzorka	128
Slika 5.1	Koraci u razvoju regresijskih modela	142

Slika 5.2 Prikaz ukupnog, protumačenog i neprotumačenog odstupanja za jednu točku 149
Slika 5.3 Dijagram toka razvoja regresijskih modela procjene troškova toplinske energije školskih zgrada u FBiH 158

Popis tablica

Tablica 2.1	Karakteristične troškovne stavke ukupnih životnih troškova i troškova životnog ciklusa	21
Tablica 2.2	Usporedba troškova životnog ciklusa (*LCC*) za 3 studije	41
Tablica 2.3	Troškovi održavanja i uporabe javne zgrade Studentskog centra u Mostaru	42
Tablica 2.4	Pokazatelji potrošnje energije u Velikoj Britaniji	44
Tablica 3.1	Razdoblja izgradnje javnih zgrada u BiH	54
Tablica 3.2	Ukupan broj javnih zgrada u BiH po tipovima	56
Tablica 3.3	Ukupan broj javnih zgrada u BiH po administrativnim cjelinama	56
Tablica 3.4.	Ukupan broj javnih zgrada u FBiH po tipovima	57
Tablica 3.5	Raspodjela korisne površine (A_k) javnih zgrada u FBiH po tipovima	57
Tablica 3.6	Raspodjela korisne površine (A_k), volumena grijanog zraka (V_e), površine ovojnice grijanog dijela (A) zgrada za obrazovanje u FBiH	59
Tablica 3.7	Raspodjela vrijednosti faktora oblika (f_o), koeficijenta prolaska topline (U), ukupne potrebne toplinske energije za grijanje $Q_{H,nd}$ i specifične potrebne toplinske energije za grijanje $Q'_{H,nd}$ zgrada za obrazovanje u FBiH	59
Tablica 3.8	Karakteristike zgrada za obrazovanje u FBiH prema razdoblju izgradnje	60
Tablica 3.9	Ukupan broj zgrada za obrazovanje u FBiH u odnosu na klimatske regije	62
Tablica 4.1	Podatci o broju školskih zgrada u FBiH iz uzorka i korisnim površinama (A_k) u odnosu na razdoblje izgradnje i klimatske regije	72
Tablica 4.2	Podatci o prosječnim vrijednostima geometrijskih karakteristika (starost, korisna površina (A_k), volumen grijanog zraka (V_e), površina ovojnice grijanog dijela (A), faktora oblika (f) i faktora kompaktnosti (f_o) školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije	82
Tablica 4.3	Podatci deskriptivne statistike za opće i geometrijske podatke školskih zgrada u FBiH iz uzorka u odnosu na godinu izgradnje, starost, korisnu površinu (A_k), volumen grijanog zraka (V_e) površinu ovojnice(A), faktor oblika (f) i faktor kompaktnosti (f_o)	83
Tablica 4.4	Podatci o prosječnim površinama građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije	84
Tablica 4.5	Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema prosječnim površinama građevinskih dijelova ovojnice (zidova, podova, stropova, otvora i ukupne ovojnice)	85
Tablica 4.6	Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema U - vrijednostima (W/m^2K) građevinskih dijelova ovojnice (zidova, podova, stropova, otvora i ukupne ovojnice)	87
Tablica 4.7	Podatci o prosječnim U - vrijednostima građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije	91
Tablica 4.8	Podatci o prosječnim U - vrijednostima građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka i vrijednosti prema pravilnicima	92

Tablica 4.9 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema vrijednostima koeficijenta transmisijske izmjene topline $H'_{tr,adj}$ (W/m²K) i ukupnog koeficijenta izmjene topline H' (W/m²K) 95

Tablica 4.10 Podatci o prosječnim vrijednostima koeficijenta transmisijske izmjene topline $H'_{tr,adj}$, koeficijenta ventilacijske izmjene topline H'_{ve}, ukupnog koeficijenta izmjene topline H' i dopuštenih vrijednosti koeficijenta transmisijske izmjene topline $H'_{tr,adj,dop}$ (W/m²K) školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije 96

Tablica 4.11 Podatci deskriptivne statistike prema stvarnoj specifičnoj isporučenoj toplinskoj energiji za grijanje ($Q'_{H,del}$) i specifičnoj električnoj energiji (E'_{del}) školskih zgrada u FBiH iz uzorka 98

Tablica 4.12 Podatci deskriptivne statistike prema stvarnoj specifičnoj isporučenoj toplinskoj energiji za grijanje ($Q'_{H,del}$)školskih zgrada u FBiH iz uzorka prema klimatskim regijama RS i RJ FBiH 99

Tablica 4.13 Podatci o prosječnim vrijednostima stvarne specifične potrošnje isporučene toplinske energije za grijanje ($Q'_{H,del}$), specifične potrošnje električne energije (E'_{del}), ukupne specifične potrošnje toplinske i električne energije te udjeli u ukupnoj potrošnji školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije 100

Tablica 4.14 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema vrijednostima proračunske specifične potrebne godišnje toplinske energije za grijanje ($Q'_{H,nd,cal}$) i proračunske specifične godišnje isporučene toplinske energije ($Q'_{H,del,cal}$) 107

Tablica 4.15 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema vrijednostima proračunske specifične potrebne godišnje toplinske energije za grijanje ($Q'_{H,nd,cal}$) prema regijama sjever (RS) i jug (RJ) u FBiH 108

Tablica 4.16 Podatci o prosječnim vrijednostima proračunske specifične godišnje potrebne toplinske energije za grijanje ($Q'_{H,nd,cal}$), energetskom razredu, proračunske godišnje isporučene toplinske energije za grijanje ($Q'_{H,del,cal}$) (kWh/m²god), stvarne godišnje isporučene toplinske energije za grijanje ($Q'_{H,del}$) i prosječnog odnosa stvarne i proračunske vrijednosti isporučene toplinske energije školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije 110

Tablica 4.17 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema stvarnim vrijednostima jediničnog troška energenata ($UC_{QH,del}$), jediničnog troška električne energije ($UC_{E,del}$), specifičnog godišnjeg troška isporučene toplinske energije ($C'_{QH,del}$) i specifičnog godišnjeg troška električne energije ($C'_{E,del}$) 117

Tablica 4.18	Podatci o prosječnim vrijednostima specifičnog godišnjeg troška za isporučenu toplinsku energiju ($C'_{QH,del}$), specifičnog godišnjeg troška za utrošenu električnu energiju ($C'_{E,del}$), ukupnog specifičnog godišnjeg troška isporučene energije ($C'_{e,del}$) te udjela troškova u ukupnim troškovima energije školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije	119
Tablica 4.19	Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema vrijednostima prosječnog jediničnog troška energenata ($UC_{QH,del}$) za grijanje	121
Tablica 4.20	Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema vrijednostima specifičnog godišnjeg troška isporučene toplinske energije ($C'_{QH,del}$) za grijanje u odnosu na korišteni energent	123
Tablica 4.21	Podatci o prosječnim vrijednostima stvarne specifične isporučene toplinske energije ($Q'_{H,del}$), stupnja učinkovitosti sustava grijanja (η_{sys}), jediničnog troška energenata ($UC_{QH,del}$), stvarnog specifičnog godišnjem troška energenata ($C'_{QH,del}$) i proračunskog specifičnog godišnjeg troška energenta ($C'_{QH,del,cal}$) školskih zgrada u FBiH iz uzorka	124
Tablica 5.1	Popis mogućih neovisnih varijabli za razvoj regresijskih modela procjene troškova toplinske energije školskih zgrada u FBiH iz uzorka	135
Tablica 5.2	Popis mogućih ovisnih varijabli za razvoj regresijskih modela procjene troškova toplinske energije školskih zgrada u FBiH iz uzorka	138
Tablica 5.3	Podjela broja školskih zgrada u FBiH iz uzorka u odnosu na set za razvoj i validaciju regresijskih modela	144
Tablica 5.4	Regresijski modeli razvijeni na temelju seta za razvoj (training) za ovisne varijable	160
Tablica 5.5	Vrijednosti statističkih metoda ocjene regresijskih modela svedenih na ovisnu varijablu Y2,cal (godišnji proračunski trošak isporučene toplinske energije $C_{QH,del,cal}$)	166
Tablica 5.6	Rangiranje regresijskih modela svedenih na ovisnu varijablu Y2,cal preko statističkih metoda RMSE i MAPE	168
Tablica 5.7	Rangiranje korigiranih regresijskih modela svedenih na ovisnu varijablu Y2,cal preko statističkih metoda RMSE i MAPE	172
Tablica 5.8	Rangiranje jednostavnijih regresijskih modela svedenih na ovisnu varijablu Y2,cal preko statističkih metoda RMSE i MAPE	176
Tablica 5.9	Rangiranje korigiranih jednostavnijih regresijskih modela svedenih na ovisnu varijablu Y2,cal preko statističkih metoda RMSE i MAPE	177
Tablica 5.10	Rang odabranih regresijskih modela prema R^2 i RMSE	178
Tablica 5.11	Sažeti prikaz statističke ocjene prema RMSE i MAPE odabranih regresijskih modela za proračun ukupnih proračunskih godišnjih troškova za isporučenu toplinsku energiju ($C_{QH,del,cal}$)	182

Tablica 5.12 Analiza vrjednovanja neovisnih varijabli za regresijski model Y0,cal,spec-2 185
Tablica 5.13 Analiza vrjednovanja neovisnih varijabli za regresijski model Y0,cal,spec-4 186
Tablica 5.14 Analiza vrjednovanja neovisnih varijabli za regresijski model Y0,cal,spec-7 186
Tablica 5.15 Analiza vrjednovanja neovisnih varijabli za regresijski model Y0,cal,spec-10 186

Popis kratica i simbola

SDG	Broj stupanj dana grijanja
GI	Godina izgradnje
A_k	Korisna površina
V_e	Volumen grijanog dijela zgrade
V	Neto volumen grijanog dijela zgrade
A	Površina ovojnice grijanog dijela zgrade
f	Faktor oblika $f=A/A_k$
f_o	Faktor kompaktnosti $f_o=A/V_e$
A_Z	Površina zidova ovojnice
A_P	Površina podova ovojnice
A_S	Površina stropova ovojnice
A_O	Površina otvora ovojnice
U_Z	U - vrijednost za zidove
U_P	U - vrijednost za podove
U_S	U - vrijednost za stropove
U_O	U - vrijednost za otvore
U	U - vrijednost ovojnice
H_{tr}	Koeficijent transmisijske izmjene topline
$H'_{tr,adj}$	Koeficijent transmisijske izmjene topline po površini ovojnice
H_D	Koeficijent transmisijske izmjene topline prema vanjskom okolišu
H_G	Koeficijent transmisijske izmjene topline prema tlu
H_U	Koeficijent transmisijske izmjene topline kroz negrijan prostor
H_A	Koeficijent transmisijske izmjene topline kroz susjedne zgrade
H_{ve}	Koeficijent ventilacijske izmjene topline
H'_{ve}	Koeficijent ventilacijske izmjene topline po površini ovojnice
H	Ukupan koeficijent izmjene topline
H'	Ukupan koeficijent izmjene topline po površini ovojnice
$Q_{H,nd}$	Godišnja potrebna toplinska energija za grijanje
$Q'_{H,nd}$	Godišnja specifična potrebna toplinska energija za grijanje
$Q''_{H,nd}$	Godišnja specifična potrebna toplinska energija za grijanje

$Q_{H,del}$	Godišnja isporučena toplinska energija za grijanje
$Q'_{H,del}$	Godišnja specifična isporučena toplinska energija za grijanje
E_{del}	Godišnja isporučena električna energija
E'_{del}	Godišnja specifična isporučena električna energija
$Q_{\mathrm{H,ht}}$	Ukupni gubitci toplinske energije u razdoblju grijanja
$\eta_{\mathrm{H,gn}}$	Faktor iskorištenja toplinskih dobitaka
$Q_{\mathrm{H,gn}}$	Ukupni toplinski dobitci u zgradi u razdoblju grijanja
Q_{tr}	Transmisijski gubitci toplinske energije u razdoblju grijanja
Q_{ve}	Ventilacijski i infiltracijski gubitci toplinske energije u razdoblju grijanja
Q_{int}	Toplinski dobitci u zgradi u razdoblju grijanja
Q_{sol}	Toplinski dobitci od sunčeva zračenja u razdoblju grijanja
$Q_{H,nd,cal}$	Godišnja proračunska potrebna toplinska energija za grijanje
$Q'_{H,nd,cal}$	Godišnja proračunska specifična potrebna toplinska energija za grijanje
$Q_{H,del,cal}$	Godišnja proračunska isporučena toplinska energija za grijanje
$Q'_{H,del,cal}$	Godišnja proračunska specifična isporučena toplinska energija za grijanje
η_{sys}	Učinkovitost sustava grijanja
$C_{QH,del}$	Godišnji trošak isporučene toplinske energije
$C'_{QH,del}$	Godišnji specifični trošak isporučene toplinske energije
$C_{E,del}$	Godišnji trošak isporučene električne energije
$C'_{E,del}$	Godišnji specifični trošak isporučene električne energije
$C_{e,del}$	Godišnji trošak isporučene energije (toplinske i električne)
$C'_{e,del}$	Godišnji specifični trošak isporučene energije
$C_{QH,del,cal}$	Godišnji proračunski trošak isporučene toplinske energije
$C'_{QH,del,cal}$	Godišnji proračunski specifični trošak isporučene toplinske energije
$UC_{QH,del}$	Jedinični trošak energenata za grijanje po isporučenoj toplinskoj energiji
$UC_{E,del}$	Jedinični trošak električne energije po isporučenoj električnoj energiji

UC_F	Jedinična cijena energenta po jedinici mjere
CV_F	Ogrjevna vrijednost energenta
n	Broj jedinica iz statističkog skupa
x_i	Pojedinačne vrijednosti kvantitativnog obilježja u statističkom skupu
$x_{\min}$	Najmanja vrijednost kvantitativnog obilježja u statističkom skupu
$x_{\max}$	Najveća vrijednost kvantitativnog obilježja u statističkom skupu
R_x	Raspon između najveće i najmanje vrijednosti kvantitativnog obilježja u statističkom skupu
$\bar{X}$	Aritmetička sredina ili prosječna vrijednost
M_e	Srednja položajna vrijednost u statističkom skupu
σ_x	Standardna devijacija
V	Koeficijent varijacije
q_1	Donji kvartil
q_3	Gornji kvartil
V_q	Koeficijent kvartilne devijacije

Popis engleskih izraza i kratica

Engleski	*Kratica*	Hrvatski
Indoor environmental quality	*IEQ*	Kvaliteta unutarnjeg okoliša
Energy performance of buildings directive	*EPBD*	Europska direktiva o energetskim karakteristikama zgrada
Heating, Ventilation, and Air Conditionig	*HVAC*	Grijanje, ventilacija i klimatizacija, GViK
Life Cycle Assessment	*LCA*	Procjena životnog ciklusa
Life Cycle Cost	*LCC*	Troškovi životnog ciklusa
Life Cycle Energy Assessment	*LCEA*	Energetska analiza životnog ciklusa
Life Cycle Cost Assessment	*LCCA*	Procjena troškova životnog ciklusa
Target-Value Design	*TVD*	Projektirana ciljna vrijednost
Buildings operation and maintenance		Uporaba i održavanje građevina
Whole Life Costs	*WLC*	Ukupni troškovi životnog ciklusa
Whole Life Cycle Costing	*WLCC*	Ukupni životni troškovi
The facility management		Gospodarenje građevinama
The International Facility Management Association	*IFMA*	Međunarodno udruženje za upravljanje građevinama
The Association of Facilities Engineering	*AFE*	Inženjering udruženje upravljanja građevinama
The Association of Higher Education Facilities Officers	*APPA*	Udruženje službenika građevina visokoškolskih ustanova
The Facility Management Institute	*FMI*	Institut za upravljanje građevinama
The National Facility Management Institute	*NFMA*	Nacionalno udruženje za upravljanje građevinama
Life Cycle Cost Planning	*LCCP*	Planiranje troškova životnog ciklusa
Full Year Effect Costs	*FYEC*	Ukupni godišnji efektivni troškovi
Life Cycle Cost Analysis	*LCCA*	Analiza troškova životnog ciklusa
Life Cycle Cost Management	*LCCM*	Upravljanje troškovima životnog ciklusa
Maintenance cost		Troškovi održavanja
Operation cost		Troškovi uporabe
Guidelines for Life Cycle Cost Analysis		Vodič za analizu troškova životnog ciklusa
Life Cycle Energy	*LCE*	Energija životnog ciklusa
Sustainable Target Value	*STV*	Projektiranje održive ciljne vrijednosti
United Nations Development Programme	*UNDP*	Razvojni program Ujedinjenih nacija
American Society of Civil Engineers	*ASCE*	Američko društvo građevinskih inženjera
Energy Management Information System	*EMIS*	Informacijski sustav upravljanja energijom

Neural Networks	*NN*	Neuronske mreže
Artificial Neural Networks	*ANN*	Umjetne neuronske mreže
Fuzzy Logic	*FL*	Nejasna logika
Genetic Algorthams	*GA*	Genetski algoritmi
Training data (set)		Skup podataka za razvoj modela
Validation data (set)		Skup podataka za validaciju modela
Test set		Skup podataka za testiranje modela
Coefficient of determination	R^2	Koeficijent determinacije
Sum of Square Errors	*SSE*	Suma kvadrata pogreške predviđanja
Mean Square Error	*MSE*	Srednja kvadratna pogreška
Root Mean Square Error	*RMSE*	Korijen srednjeg kvadrata pogreške
Coefficient of Variation of the Root Mean Square Error	*CVRMSE*	Koeficijent varijacije regresijskog modela
Mean Absolute Percentage Error	*MAPE*	Srednja apsolutna postotna pogreška
Mean Percentage Error	*MPE*	Srednja postotna pogreška
Multiple Linear Regressions	*MLR*	Višestruka linearna regresija
Interquartile Range	*IQR*	Interkvartilni raspon
Lower Outer Fence	*LOF*	Donja vanjska ograda
Upper Outer Fence	*UOF*	Gornja vanjska ograda

1. Uvod

1.1 Obrazloženje teme

Na početku rada definiraju su dva pojma koja se koriste u ovom radu, a to su građevina i zgrada. U tehničkom leksikonu pod pojmom građevina se definira čovjekovo djelo nastalo gradnjom gdje su građevine složeni sklopovi s estetsko-funkcionalnim i tehničko-tehnološkom obilježjima, a njihovom gradnjom bavi se graditeljstvo. Zgrada se definira kao građevina namijenjena stanovanju te gospodarskoj, obrazovnoj, zdravstvenoj, kulturnoj ili drugoj djelatnosti u zatvorenom prostoru. Zgrade se razlikuju prema materijalu od kojega su izgrađene, izmjerama, obliku, predviđenom vijeku trajanja, a najčešće se razvrstavaju prema društvenoj ulozi i namjeni [1]. U navedenom kontekstu pojam građevina će se koristiti u širem smislu, a pojam zgrada u užem smislu i obuhvaća građevine određene namjene.

Aktualni trendovi u EU i svijetu u građevinarstvu su usmjereni na održivu gradnju, smanjenje negativnog utjecaja građevina na okoliš i smanjenje potrošnje ukupne energije u svim fazama životnog ciklusa građevine od planiranja i građenja, preko najduže faze uporabe do faze uklanjanja građevine.

Građevine koriste energiju kroz cjelokupan životni ciklus. Potrebe za energijom mogu se podijeliti na izravne i neizravne. Izravna energija koristi se za izgradnju, uporabu (korištenje), obnovu i rušenje, a kao neizravna energija troši se za proizvodnju materijala koji se koristi u građevinskim konstrukcijama i tehničkim instalacijama [2]. Energija životnog ciklusa zgrada ima dvije značajne komponente i to uporabnu (*operational*) i utjelovljenu (*embodied*) energiju. Uporabna energija je energija koja se troši tijekom faze korištenja zgrade, i to za grijanje, hlađenje, osvjetljavanje i pokretanje opreme i uređaja u zgradama. Utjelovljena energija je energija koja se koristi za eksploataciju materijala, proizvodnju materijala i građevinskih proizvoda, izgradnju, održavanje i rušenje zgrade, kao i sav povezani prijevoz s navedenim aktivnostima. Pristup „od kolijevke do groba“ utjelovljenu energiju definira kao ukupnu energiju korištenu u čitavom životnom ciklusu zgrade, isključujući energiju koja se koristi za rad zgrade, odnosno uporabnu energiju [3].

Povijesno gledano, zgrade se projektiraju na temelju razgovora naručitelj - arhitekt, a kada su nacrti (projektna tehnička dokumentacija) završeni, troškovi se procjenjuju. Cijena (trošak) je u ovakvom slučaju ishod projektiranja, a ne smjernica u projektiranju [4]. U posljednjih nekoliko desetljeća, a s obzirom na to da troškovi energije značajno rastu, investitori postaju osvješteniji i sve više dolazi do izražaja briga o troškovima uporabe i održavanja zgrada, naročito kod javnih zgrada ili prilikom ugovaranja projekata izgradnje primjenom javno-privatnog partnerstva.

Troškovi energije postali su sve važniji čimbenici u fazi projektiranja i uporabe bilo koje građevine. Statistički modeli predviđanja troškova energije koriste se već duže vrijeme. Svrha preciznih tehnika predviđanja su pouzdane procjene vjerojatne potrošnje i troškova energije [5].

Za ukupan životni ciklus zgrada, najveći utjecaji na okoliš najdominantniji je u fazi uporabe zbog potrošnje energije. Procijenjeno je da u fazi uporabe potrošnja energije predstavlja približno 80–90% ukupne potrošnje energije tijekom životnog ciklusa, dok se 10-20% troši na proizvodnju materijala, a manje od 1% kroz aktivnosti na kraju životnog vijeka zgrade [6].

Nužna je potreba za razumijevanjem trenutnog stanja potrošnje energije i regulirajućih utjecaja na okoliš. Projektiranje i izgradnja novih zgrada pruža mogućnost za smanjenje utjecaja na okoliš, a kao rezultat toga, smanjenje uporabnih troškova i problema s nestašicom energije [4].

Građevinski sektor uključuje aktivnosti vezane uz izgradnju novih zgrada ili obnavljanje postojećih. U fazi uporabe i održavanja javljaju se aktivnosti vezane za održavanje ugodnih uvjeta u zgradi, potrošnju energije, korištenje vode i stvaranje otpada. Uz navedeno zakonska regulativa obvezuje vlasnika zgrade na trajne aktivnosti održavanja zgrade koje sadrže tehnička i administrativna djelovanja kako bi se tijekom cijeloga vijeka uporabe zgrade u cjelini i svim njezinim dijelovima osigurala razina služnosti u zadovoljavajućim granicama. Održavanje zgrade podrazumijeva niz zakonom propisanih pregleda, popravaka i zamjene istrošenih građevinskih sklopova i materijala. Zgrade imaju dug životni vijek tijekom kojeg nastaju troškovi u obliku troškova uporabe i održavanja, troškova prilagođavanja promjenjivim potrebama tijekom vremena i drugih direktnih i indirektnih troškova. Troškovi koji nastaju uporabom energije odnose se na potrošnju energije u fazi građenja kao i u fazi uporabe u vidu uporabne energije. Uporabna energija u zgradama je energija potrebna za kondicioniranje prostora (grijanje, hlađenje i ventilaciju), pripremu tople potrošne vode, kuhanje i osvjetljenje, zajedno s energijom za rad uređaja i opreme [7, 8].

Istraživanje na nizozemskim stambenim zgradama pokazuje da potrošena energija na izgradnji zgrade (samo konstrukcija bez tehničkih instalacija) iznosi 52 do 106 MJ/m^{2}god., dok za uporabnu energiju raspon iznosi od 124 do 682 MJ/m^{2}god. Udio energije potrošene na izgradnju standardnih kuća iznosi oko 10–12% ukupne potrošnje energije, dok u energetski učinkovitim kućama udio iznosi 36–46% zbog manje potrošnje uporabne energije [9].

Europski sektor građevinarstva nudi velike potencijale za uštedu, koji su tek površno iskorišteni. Ovaj sektor čini 40% ukupne europske finalne potrošnje energije i glavni je čimbenik emisija stakleničkih plinova. Oko 75% zgrada su energetski neučinkovite, a uz trenutnu stopu obnove od 1% godišnje trebalo bi oko stoljeća da se iste dekarboniziraju na moderne razine s niskim udjelom ugljika [10].

Kvaliteta unutarnjeg okoliša (*Indoor environmental quality, IEQ*) novi je koncept koji se ne bavi samo toplinskim uvjetima već i kvalitetom zraka, osvjetljenjem i akustikom. S obzirom na to da brojne interakcije između energetske učinkovitosti zgrade i IEQ, ova se dva koncepta moraju rješavati i istraživati na povezan način. IEQ i energija usko su povezani, a samo integrirana analiza može osigurati da poboljšanja u energetskoj učinkovitosti ne smanjuju IEQ, a da poboljšanja u IEQ ne smanjuju ni energetsku efikasnost [11].

Troškovi uporabe energije zgrada direktno su vezani s količinom potrošene energije koja ovisi o tehničkim karakteristikama iste, instaliranim uređajima i opremi i ponašanju korisnika. Porast potrošnje energije u zgradama, a time i emisije stakleničkih plinova utjecalo je na poduzimanje određenih aktivnosti na poboljšanju energetskih karakteristika zgrada čime se smanjuje potreba za energijom, a time i troškovi uporabe. Aktualni trendovi u građevinarstvu su usmjereni na provođenje strategija, planova i mjera obuhvaćenih konceptom energetske učinkovitosti.

Energetska učinkovitost zgrada došla je na čelo političkih rasprava zbog visokih cijena energije i zabrinutosti za klimatske promjene te je postala ključna u cilju smanjenja potrošnje energije na nacionalnoj razini. Poboljšanje energetske učinkovitosti u novim zgradama jedan je od najlakših načina za smanjenje potrošnje (uporabe) i troškova energije, te smanjenja emisije CO_2 [12].

Pokrenuti su različiti europski projekti, kao što je *Educa-RUE* (racionalna uporaba energije), sufinanciran od Europske komisije u okviru programa *Intelligent Energy Europe*, čiji je osnovna namjera poboljšati energetske karakteristike u građevinskom sektoru na lokalnoj razini, obraćajući posebnu pažnju na obrazovne zgrade, i usmjeren na ubrzavanje provedbe Europske direktive o energetskim karakteristikama zgrada (*Energy performance of buildings directive*, *EPBD, 2010/31/EU*) [13].

Smanjenje potrošnje energije (ušteda energije) ubraja se u mjere koje su najbrže, najisplativije i najviše utječu na načine smanjenja emisija stakleničkih plinova. Ušteda energije se definira kao rezultat poboljšanja energetske učinkovitosti i mjeri se kao razlika potrošnje energije prije i poslije poduzetih mjera poboljšanja energetske učinkovitosti. Uštede energije mogu se ostvariti nizom mjera, uključujući pametno projektiranje, poboljšanje izolacije, korištenje niskoenergetskih uređaja, visokoučinkovitim sustavima ventilacije i grijanja/hlađenja, te ponašanja korisnika [6].

Održivo energetski učinkovito projektiranje zgrada smanjuje potrebu za energijom za grijanje i hlađenje, a provedba projektiranih mjera u fazi izgradnje zgrada smanjuje ukupne troškove životnog ciklusa građevine [14]. Osim energetski učinkovitih građevinskih dijelova vrlo bitna je i energetski učinkovita tehnologija opreme koja se ugrađuje u zgradu i koja se može definirati kao dio opreme za

napajanje, ventilaciju, grijanje i/ili hlađenje i koja se oslanja na resurse koji nemaju dugoročni štetni utjecaj na okoliš [15].

Potrošnja energije rezultat je ne samo toplinskih karakteristika zgrada nego i ponašanja korisnika koje je složenije za procjenu i kvantifikaciju. Istraživanja ponašanja rade se dugi niz godina, a dokazano je da se kategoriziranjem obrazaca ponašanja korisnika (status zauzetosti, broj korisnika, mjesto, aktivnost korisnika) može procijeniti potreba za energijom korisnika [16].

Potrebna energija za grijanjem i hlađenjem zgrada predstavlja glavni utjecaj civilnog sektora na okoliš. Potrošnja utječe i na troškove rada i održavanja sustava grijanja, ventilacije i klimatizacije (GViK, engleski *Heating, Ventilation, and Air Conditionig, HVAC*) zgrade i na uvjete udobnosti u zatvorenom prostoru [17]. Potencijal uštede energije postojećih zgrada i mjere energetske učinkovitosti su glavni istraživački subjekti diljem svijeta, fokusirajući se na širok raspon tema kao što su propisi o uštedi energije, procjena životnog ciklusa (*Life cycle assessment, LCA*), metodologije uspoređivanja energetske učinkovitosti, najbolje mjere uštede energije za različite klime i lokacije i utjecaj karakteristika ovojnice na GViK sustav [18].

Kako bi se smanjila potrošnja energije i njezini učinci na klimu potrebno je nekoliko strategija, uključujući smanjenje potražnje za energijom i veću energetsku učinkovitost. Pokazuje se kako su za dulja vremenska razdoblja i scenarije s višim cijenama energije, veća početna ulaganja u energetsku učinkovitost zgrada najisplativija. Nakon početnih nekoliko godina, uštede nastale smanjenjem troškova energije povezane s energetski učinkovitim zgradama nadmašuju veće troškove izgradnje [19].

Pri analizi ukupnih troškova životnog ciklusa zgrada traže se optimalni troškovi u odnosu na razinu energetskih karakteristika zgrada koja dovodi do najnižih troškova tijekom cijelog životnog ciklusa, uzimajući u obzir troškove ulaganja vezane uz energiju, troškove održavanja i uporabe (uključujući troškove energije i zarade od proizvedene energije) i troškove zbrinjavanja ako su primjenjivi. Optimalnost troškova popraćena je minimalnim zahtjevima koji su orijentirani ne samo na kratkoročna razdoblja povrata, već i na dugoročnu prikladnost i ekonomsku optimizaciju, s krajnjim ciljem smanjenja troškova životnog ciklusa uz istovremeno održavanje visokih energetskih svojstava [20].

Također, europska Direktiva o energetskim karakteristikama zgrada (*Energy performance of buildings directive*, *EPBD 2010/31/EU*) predviđa da sve države članice uspostave usporedni metodološki okvir za izračunavanje troškovno optimalnih razina minimalnih zahtjeva energetske učinkovitosti zgrada. Metodologija izračuna troškovno optimalnih razina samo je okvir koji pruža općeniti pristup nacionalnim metodama izračuna i potrebno je prilagoditi različitim nacionalnim čimbenicima [21].

Za poboljšanje energetskih karakteristika zgrada mogu se koristiti pasivne mjere na poboljšanju toplinske izolacije građevinskih dijelova ovojnice zgrade i aktivne mjere na ugradnji učinkovitije opreme zgrade. Za procjenu energetske učinkovitosti zgrada i proračun potrošnje energije potrebni su brojni parametri kao što su toplinske karakteristike građevinskih dijelova ovojnice zgrade, transmisijski i ventilacijski gubitci, unutarnji i vanjski klimatski uvjeti. Identificiranje i kvantificiranje višestrukih koristi energetske učinkovitosti postalo je novi trend.

Iako povećanje energetske učinkovitosti zgrada obično povećava početne troškove izgradnje, uštede energije tijekom vijeka trajanja često nadoknađuju ove početne veće troškove [12]. Primjena mjera poboljšanja energetske učinkovitosti zgrada usporava se kada su troškovi energije vrlo mali dio troškova vlasnika [18].

U posljednja dva desetljeća naglo je porastao proračun utjecaja građevina na životnu sredinu (izgradnja plus uporaba građevine) [22]. Najčešće korišteni pristup je tehnika analize procjene životnog ciklusa (*Life cycle assessment, LCA*) koja omogućava analizu i mjerenje potrošnje energije životnog ciklusa i kojom se određuje utjecaj građevine na okoliš povezan s energijom. Analiza potrošnje energije tijekom cijelog životnog ciklusa građevine predstavlja osnovu na kojoj se mogu donositi projektne odluke. Proizvodnja i potrošnja energije predstavlja veliko opterećenje za okoliš u smislu iscrpljivanja resursa i s tim povezanih emisija [7].

Pregledom literature iz područja ukupnih troškova životnog ciklusa uočava se kako se autori usredotočuju na načine i metode proračuna troškova životnog ciklusa zgrada, međutim kvantitativna i praktična rješenja ostaju nedostižna, ponajprije zbog neprestanog odsustva pouzdanih podataka o troškovima životnog ciklusa zgrada [23].

Do sada provedena istraživanja i studije vezane su za troškove uporabe energije, ekološke izvedbe, troškove životnog ciklusa i integrirano projektiranje, međutim niti jedna studija ne kombinira sve aspekte zajedno kako bi se utvrdilo istodobno utjecaji energetski učinkovitosti na troškove životnog ciklusa, životni ciklus emisija ugljika i korištenje energije u integriranom projektiranju zgrada u različitim klimatskim zonama [12].

Također znatan postotak postojećih zgrada nastavit će se koristiti još mnogo godina, a ukoliko ih se ne obnovi u smislu energetskih svojstava, oni će i dalje nepotrebno trošiti velike količine energije. Zbog toga energetska obnova postojećih zgrada ima veliki potencijal za uštedu energije, a kao posljedicu i smanjenje emisije CO_2. Zgrade su najveći pojedinačni potrošač energije, a time i veliki zagađivač zraka i okoliša. Zbog dugog životnog vijeka zgrada, njihov je utjecaj na okoliš u kojem živimo dug i kontinuiran i ne možemo ga zanemarivati [24].

Nedostatak sveobuhvatnih i zajedničkih podataka o karakteristikama zgrada i pouzdanih povijesnih podataka o troškovima vezanih za sve faze životnog ciklusa zgrada utjecalo je na to da je publicirano vrlo malo istraživanja koja se bave utjecajem karakteristika zgrada na ukupne životne troškove [25].

Stoga je ovo istraživanje predstavljeno u ovom radu usmjereno na prikupljanje i analizu povijesnih podataka o karakteristikama zgrada, potrošnji i troškovima energije koja se koristi u školskim zgradama u Federaciji Bosne i Hercegovine (FBiH), kao izuzetno značajnih društvenih i javnih zgrada. Istraživanjem se želi utvrditi ovisnost između energetskih karakteristika zgrada i varijabli iz baze podataka s troškovima energije uporabe istih. Metodologija prikupljanja podataka potrebnih za ovo istraživanje prikazana je u nastavku rada.

1.2 Svrha i ciljevi istraživanja

Pregledom dosadašnjih istraživanja uočava se nedostatak empirijskih istraživanja o implikacijama karakteristika zgrada na troškove životnog ciklusa. Jedno od područja za daljnja istraživanja predstavlja integracija teorijskog pristupa i metodologije troškova životnog ciklusa s praktičnim potrebama korisnika i stručnjaka, vodeći računa o pitanjima kao što su kvaliteta podataka, jednostavnost proračuna i način tumačenja i prikaza rezultata. Također, zaključuje se kako nijedan od modela troškova životnog ciklusa ne analizira povezanost karakteristika zgrada (varijabli modela) i troškova uporabe i održavanja zgrada [26].

Među svim javnim zgradama, zbog svoje obrazovne svrhe, školske zgrade znače veliku društvenu odgovornost i važnost. Stoga su energetske karakteristike ovih zgrada od velikog značenja, zajedno s odgovarajućim razinama kvalitete unutarnjeg okoliša [27]. Toplinska udobnost važan je preduvjet u školama. Kada se postigne toplinsko zadovoljstvo korisnika zgrade, kaže se da je postignuta toplinska udobnost [28].

Budući da djeca provode oko 25% svog vremena učeći u učionicama, školske zgrade u određenoj mjeri predstavljaju drugi dom. Nadalje, u školama je puno veća popunjenost nego u bilo kojoj drugoj zgradi, te je od vitalne važnosti imati unutarnju klimu koja ne će utjecati na udobnost, zdravlje ili intelektualne performanse učenika. Istraživanja pokazuju da se rezultati ispitivanja djece smanjuju proporcionalno porastu pritužbi na IEQ faktore (toplinska udobnost, kvaliteta zraka u zatvorenom, vizualno i slušno okruženje) [11].

Ugljični dioksid (CO_2) najvažniji je staklenički plin koji se u najvećim količinama oslobađa pri korištenju fosilnih goriva u proizvodnji električne i toplinske energije, kao i u prometu i industriji. Potrošnja energije u školama često je prilično velika što utječe na visoke troškove za energiju i visoku emisiju CO_2 [29]. Osnovna pretpostavka je da identifikacija određenih ključnih parametara (razdoblje izgradnje,

namjena zgrade, geometrijske karakteristike zgrade, način uporabe, karakteristike građevinskih dijelova ovojnice zgrade) omogućuje donošenje zaključaka o potrošnji energije u pojedinačnim zgradama [30].

Ovo istraživanje će se provesti za postojeće zgrade namijenjene za obrazovanje (zgrade osnovnih i srednjih škola) u FBiH koje uz administrativne zgrade imaju najveći udio u ukupnom broju svih javnih zgrada u FBiH i čiji se troškovi uporabe i održavanja financiraju javnim sredstvima. Uz školske zgrade nalaze se i školske sportske dvorane koje sa stajališta funkcije i zajedničkih tehničkih sustava (grijanja, ventilacije, klimatizacije i elektroinstalacija) čine jednu cjelinu i zajedničku potrošnju energije (ne postoje odvojena mjerila potrošnje energije za školske zgrade i školske sportske dvorane). Stoga će se zajednički analizirati školske zgrade i školske sportske dvorane (ukoliko iste postoje). Analizirat će se karakteristike (svojstva) školskih zgrada u FBiH kao što su godina izgradnje, veličina, površina ovojnice, volumen, površine i toplinske karakteristike građevinskih dijelova ovojnice, način i režim grijanja, energent koji se koristi i klimatski podatci koji karakteriziraju lokaciju zgrade. U idućem koraku će se utvrditi povezanost karakteristika (svojstava) školskih zgrada s troškovima koji se odnose na potrošnju toplinske energije.

Istraživanja će se usmjeriti na određivanje energetskih karakteristika (performansi) građevinskih dijelova ovojnice zgrade u odnosu na razdoblje izgradnje, te na potrošnju toplinske i električne energije i troškove koji se odnose na korištenje energije.

Da bi se procijenile energetske karakteristike (performanse) zgrada, potrebno je usporediti izračunate ili izmjerene performanse zgrade s nekom referentnom vrijednošću ili okvirom (dopuštenom vrijednošću sukladno važećim propisima). Te vrijednosti mogu predstavljati karakteristike građevinskih dijelova ovojnice zgrada (poput U-vrijednosti) ili potrošnje energije pojedinih sustava zgrada [31].

Istraživanje energetskih karakteristika zgrada trajna su točka razmišljanja među istraživačima i praktičarima. Problem ocjene energetskih karakteristika zgrada može se promatrati kroz dva glavna pristupa, ocjenu potreba i ocjenu stvarne uporabne potrošnje. Potrebe se mogu definirati kao proračun koji se temelji na energiji kroz energetski model zgrade. Stvarne potrebe povezane su sa svakodnevnom uporabom i korištenjem zgrade. Oba pristupa na isti problem gledaju iz različite, ali komplementarne perspektive [32].

Povećanje dostupnosti velike količine podataka o energetskim karakteristikama zgrada omogućilo je razvoj metodologija koje se koriste statističkim tehnikama za predviđanje i procjenu energetskih karakteristika na temelju postojećih skupova podataka više zgrada. Većina statističkih modela koristi se nekom vrstom regresije za modeliranje i objašnjenje energetskih karakteristika zgrada. Dodavanjem

informacija o daljnjim varijablama i statističkim mapiranjem odnosa između ovih varijabli i potrošnje energije, ti se modeli zatim mogu koristiti za predviđanje energetskih karakteristika zgrada na temelju njihovih karakteristika što je prikazano na slici 1.1 [31].

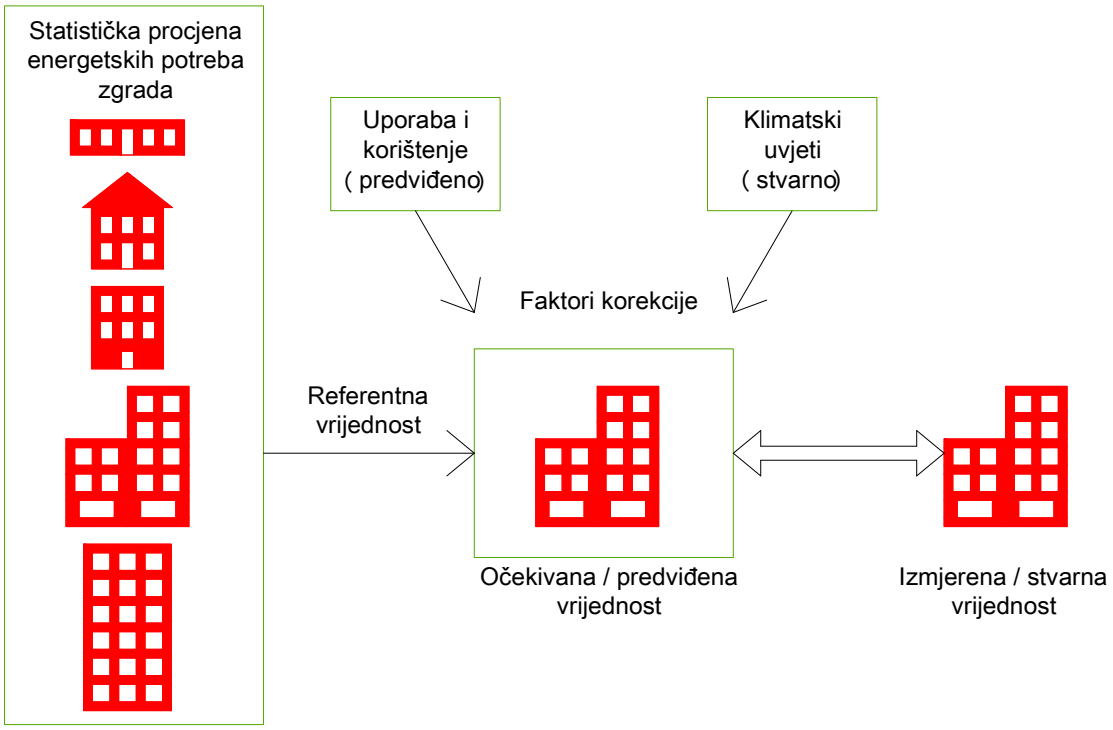

Slika 1.1 Procjena energetskih karakteristika zgrade u usporedbi sa statističkim mjerilima [31]

Svrha ovog istraživanja je analiza energetskih karakteristika (performansi) školskih zgrada u FBiH i određivanje njihove povezanosti s troškovima toplinske energije kroz razvoj novih modela koji omogućavaju jednostavniju i bržu procjenu (predviđanje) troškova toplinske energije. Dobiveni matematički modeli mogu se koristiti:

- u inženjerskoj praksi u fazi projektiranja kod analiza i proračuna ukupnih troškova životnog ciklusa zgrada u svrhu vrjednovanja varijantnih rješenja i donošenja investicijskih odluka,
- prilikom izrade detaljnih energetskih pregleda u svrhu jednostavnije procjene potrošnje toplinske energije i troškova uporabe energije i
- za potrebe vlasnika zgrada u svrhu upravljanja istim, donošenja odluka, planova i mjera za poboljšanje energetskih karakteristika i smanjenja potrošnje i troškova energije.

Opći ciljevi ovog istraživanja su:

- prikupljanje povijesnih podataka o karakteristika školskih zgrada u FBiH,
- prikupljanje povijesnih podataka o troškovima uporabe koji se odnose na potrošnju toplinske energije i električne energije školskih zgrada u FBiH,

- analizirati i utvrditi energetske karakteristike (performanse) postojećih građevinskih dijelova ovojnice u odnosu na razdoblje izgradnje školskih zgrada u FBiH,
- analizirati i utvrditi energetske karakteristike (performanse) vezano za potrošnju toplinske i električne energije, te utvrditi troškove uporabe koji se odnose na potrošnju energije školskih zgrada u FBiH,
- istražiti utjecaj pojedinih karakteristika (varijabli) zgrada na troškove toplinske energije školskih zgrada u FBiH i
- istražiti mogućnost izrade novih matematičkih modela procjene potrošnje i troškova toplinske u funkciji pojedinih karakteristika (varijabli) školskih zgrada u FBiH.

Specifični cilj ovog istraživanja jeste izrada novih matematičkih modela koji će se moći koristiti za procjenu troškova toplinske energije školskih zgrada u FBiH koji se općenito može prikazati u obliku funkcije:

$$y = f(x_1, x_2, ..., x_n) \tag{1.1}$$

gdje su:

- y troškovi toplinske energije (zavisna varijabla),
- $x_1, x_2, ..., x_n$ parametri (neovisne varijable) od kojih ovise troškovi y .

Neki od parametara, odnosno varijabli koji utječu na potrošnju toplinske energije i od kojih ovise troškovi potrošnje toplinske energije su sastav konstrukcije (prvenstveno vanjske ovojnice zgrade, vrsta i debljina pojedinih slojeva) i način izgradnje – tehnologija građenja u odnosu na razdoblje izgradnje, klimatski uvjeti na lokaciji zgrade, trajanje sezone grijanja, učinkovitost ugrađenih sustava i instalacija za grijanje prostora, razina održavanja tih sustava, broj korisnika i režim rada grijanja, vrsta energenta i njegova cijena.

Izrada matematičkog modela procjene troškova energije je složen sustav zbog složenosti varijabli koje su uključene u izgradnju modela. Problem se može pojednostaviti korištenjem konačnih i pouzdanih podataka o parametrima potrošnje energije prikupljenih tijekom određenog vremenskog razdoblja kao ulaznih podataka u model, te ukupnih troškova energije kao izlaznih vrijednosti stanja sustava [33].

1.3 Metode istraživanja i definiranje hipoteza istraživanja

Ovo istraživanje je usmjereno na postojeće školske zgrade u FBiH koje su najvećim dijelom izgrađene prije nekoliko desetljeća uglavnom bez toplinske izolacije građevnih dijelova ovojnice što ima veliki utjecaj na potrošnju i troškove energije u ukupnim troškovima uporabe i održavanja. Kako bi se istražile

koje varijable imaju najveći utjecaj na troškove toplinske energije koristit će se deduktivni i induktivni pristup.

Prvi dio istraživanja se odnosi na pregled dostupne postojeće literature i radova iz područja troškova životnog ciklusa zgrada (*Life Cycle Cost, LCC*). Istražit će se metode i modeli proračuna troškova životnog ciklusa te analizirati struktura i udjeli pojedinih komponentni troškova životnog ciklusa. Kako troškovi uporabe i održavanja ovise o karakteristikama zgrada naglasak se stavlja na troškove koji nastaju uporabom toplinske energije za grijanje. Pregledom literature utvrditi će se pokazatelji potrošnje toplinske energije za školske zgrade. Trendovi su usmjereni na koncept energetske učinkovitosti kojim se primjenom određenih mjera poboljšanja smanjuje potrošnja energije, a time i troškovi uporabe istih.

Drugi dio istraživanja, koristeći induktivni pristup (od pojedinačnog k općem), odnosi se na prikupljanje i analizu podataka iz uzorka školskih zgrada kako bi se proučavanjem karakteristika skupa iz uzorka utvrdila zajednička svojstva koja se pripisuju cijelom skupu svih školskih zgrada u FBiH. Cijeli skup ili populacija u ovom istraživanju su zgrade namijenjene za obrazovanje (školske zgrade zajedno sa školskim sportskim dvoranama) u FBiH, a uzorak predstavlja skup opaženih rezultata o svojstvima članova populacije osnovnog skupa. Kako bi se utvrdile karakteristike školskih zgrada u FBiH pristupilo se traženju i prikupljanju podataka o karakteristikama građevinskih dijelova vanjske ovojnice, o potrošnji energije, troškovima potrošnje energenata, kao i o drugim podatcima neophodnim za provedbu ovog istraživanja. Postavlja se pitanje na koji način doći do vjerodostojnih i pouzdanih podataka?

2018. godine u Bosni i Hercegovini (BiH) izrađen je dokument pod nazivom ''Tipologija javnih zgrada u BiH'' koji sadrži općenite podatke o pojedinim tipovima javnih zgrada u BiH i njihovim karakteristikama, ali ne sadrži podatke o troškovima uporabe istih. U tipologiji javnih zgrada u BiH dana je podjela ukupnog broja javnih zgrada u BiH u odnosu na namjenu i u odnosu na razdoblje izgradnje. Navedeni dokument predstavlja polaznu osnovu za ovo istraživanje i analizu školskih zgrada u FBiH. U “Informacijskom sustavu energetske učinkovitosti (*ISSE*) FBiH“ kojim upravlja Fond za zaštiti okoliša FBiH unose se podatci o potrošnji energije javnih zgrada u FBiH. ISEE sustav tek je u razvoju i vrlo mali dio nositelja podataka je završio unos podataka koji dijelom nisu potpuni, dovoljni i potrebni za provođenje ovog istraživanje jer ne postoje podatci o karakteristikama građevinskih dijelova vanjske ovojnice, površini ovojnice, volumenu grijanog prostora, faktoru oblika, površinama i drugim karakteristikama bitnim za ovo istraživanje. Zbog navedenog pristupilo se traženju drugog izvora podataka koji nedostaju.

Od 2010. godine pokrenuti su projekti povećanja energetske učinkovitosti u sektoru javnih institucija u FBiH na temelju analize potrošnje energije i mjera za poboljšanje energetske učinkovitosti definiranih u dokumentima detaljnih energetskih pregleda koje izrađuju stručne ovlaštene osobe (osobe koje su prošle program obuke i dobile ovlaštenja) prema propisanim uputama i smjernicama za izradu istih.

Shodno gore navedenom zaključeno je da se ovo istraživanje u dijelu koji se odnosi na karakteristike zgrada, potrošnju i troškove energije bazira na podatcima prikupljenim iz dokumenata detaljnih energetskih pregleda ili audita (DEA) koje su radile stručne kvalificirane osobe te se isti podatci mogu smatrati validnim, pouzdanim i reprezentativnim za donošenje zaključaka.

Plan istraživanja se sastoji od sljedećih koraka:

1. pregled literature i dosadašnjih istraživanja vezanih za troškove uporabe i održavanja zgrada s posebnim osvrtom na školske zgrade i potrošnju toplinske energije s troškovima vezanim za potrošnju toplinske energije,
2. prikupljanje i odabir podataka o građevinskim karakteristikama, potrošnji energije i troškovima potrošnje energije školskih zgrada u FBiH iz dostupnih dokumenata detaljnih energetskih pregleda,
3. statistička analiza prikupljenih podataka i interpretacija rezultata o općim, geometrijskim i toplinskim karakteristikama građevinskih dijelova ovojnice, potrošnji i troškova toplinske i električne energije školskih zgrada u FBiH,
4. utvrđivanje energetskih karakteristika (performansi) postojećeg stanja građevinskih dijelova ovojnice i potrošnje toplinske energije u odnosu na razdoblje izgradnje školskih zgrada u FBiH, izrada i testiranje matematičkih modela procjene potrebne toplinske energije i troškova toplinske energije na temelju prikupljenih podataka i
5. donošenje zaključaka i smjernica za daljnja istraživanja.

Definirane su radne hipoteze istraživanja:

- moguće je utvrditi energetske karakteristike (performanse) postojećih školskih zgrada u FBiH (korisna površina, površina ovojnice, volumen grijanog prostora, toplinske karakteristike građevinskih dijelova ovojnice, način i režim grijanja, učinkovitost sustava grijanja, energent koji se koristi za grijanje) u odnosu na razdoblje izgradnje na temelju prikupljanih povijesnih podataka iz dokumenata detaljnih energetskih pregleda,
- moguće je analizirati i utvrditi potrošnju toplinske i električne energije postojećih školskih zgrada u FBiH u odnosu na razdoblje izgradnje na temelju prikupljanih povijesnih podataka iz dokumenata detaljnih energetskih pregleda,

- moguće je istražiti utjecaj pojedinih karakteristika zgrada (godina izgradnje, korisna površina, površina ovojnice, volumen grijanog prostora, toplinske karakteristike građevinskih dijelova ovojnice, način i režim grijanja, učinkovitost sustava grijanja, energent koji se koristi za grijanje, klimatski podatci s obzirom na lokaciju zgrade) na troškove toplinske energije školskih zgrada u FBiH i
- moguće je izraditi nove matematičke modele procjene toplinske energije i troškova toplinske energije koji će se zasnivati na prethodno utvrđenim karakteristikama iz uzorka postojećih školskih zgrada u FBiH.

U ovome radu postavljena je nul-hipoteza H_0 kako se neovisnim varijablama (karakteristikama zgrada) ne mogu predvidjeti troškovi toplinske energije, odnosno alternativna hipoteza H_1 kako se neovisnim varijablama (karakteristikama zgrada) mogu procijeniti troškovi toplinske energije školskih zgrada u FBiH.

Znanstvena hipoteza ovog istraživanja jeste da se neovisnim varijablama ili karakteristikama školskih zgrada u FBiH (godina izgradnje, korisna površina, površina ovojnice, volumen, toplinske karakteristike građevinskih dijelova ovojnice, način i režim grijanja, učinkovitost sustava grijanja, energent koji se koristi za grijanje, klimatski podatci s obzirom na lokaciju zgrade) kroz razvoj novih matematičkih modela mogu predvidjeti ovisne varijable, odnosno troškovi toplinske energije školskih zgrada u FBiH.

1.4 Struktura rada i očekivani znanstveni doprinos

Rad se sastoji od 6 poglavlja kroz čiji slijed su opisani svrha, ciljevi, metodologija, hipoteze i rezultati ovog istraživanja.

Prvo uvodno poglavlje odnosi se na obrazloženje teme, svrhu, ciljeve i metodologiju istraživanja s definiranjem hipoteze istraživanja. Općenito, istraživanja pokazuju nedostatak sveobuhvatnih i pouzdanih povijesnih podataka, o karakteristikama zgrada i troškovima vezanih za sve faze životnog ciklusa zgrada. Stoga je ovo istraživanje usmjereno na prikupljanje povijesnih podataka o postojećim javnim školskim zgradama u FBiH, njihovim karakteristikama, troškovima toplinske energije, te istraživanju međusobnih utjecaja karakteristika zgrada i potrošnje i troškova toplinske energije.

Pregled literature i dosadašnjih istraživanja o troškovima uporabe, održavanja i životnom ciklusu zgrada u drugom poglavlju istraženi su pristupi i metode kojima se sagledavaju i proračunavaju ukupni troškovi životnog ciklusa zgrada. Dan je pregled struktura troškova i dostupnih pokazatelja o veličini pojedinih troškova s naglaskom na školske zgrade i potrošnju toplinske energije od kojih ovise troškovi istih. Istraživanja su također usmjerena na traženje troškovno optimalnih razina minimalnih zahtjeva

energetske učinkovitosti zgrada čiji je cilj smanjenje potrošnje energije i utjecaja emisija plinova na okoliš.

Treće poglavlje je vezano za istraživanje podataka o veličini i karakteristikama zgrada namijenjenih za obrazovanje u FBiH obrađenih u dokumentu pod nazivom ''Tipologija javnih zgrada u BiH''. U navedenom dokumentu definirani su veličina i tipovi zgrada u odnosu na namjenu kao i razdoblje izgradnje. Definirana su razdoblja izgradnje s općim karakteristikama, te karakteristike zgrada namijenjenih za obrazovanje u odnosu na razdoblja izgradnje. Prikazan je pregled stanja i zakonski okvir u BiH. Kako bi se provelo istraživanje potrebno je bilo prikupiti uzorak s pouzdanim podatcima koji će služiti traženju odgovora na postavljene ciljeve. Prikupljeno je 185 dokumenata detaljnih energetskih pregleda (DEA) školskih zgrada (osnovnih i srednjih škola) u FBiH koji predstavljaju bazu podataka za provedbu ovog istraživanja.

U četvrtom poglavlju se analiziraju energetske karakteristike školskih zgrada u FBiH na temelju statističke obrade prikupljenih podataka iz uzorka u kojem su utvrđene opće, geometrijske i toplinske karakteristike školskih zgrada iz uzorka u odnosu na razdoblje izgradnje. Zatim je izvršena analiza stvarne potrošnje toplinske i električne energije. Usporedbom stvarne potrošnje toplinske energije u odnosu na proračunsku toplinsku energiju određen je stupanj zadovoljenja toplinske ugodnosti. Analizirani su troškovi toplinske i električne energije uz zaključak kako je smanjenje troškova energije moguće postići primjenom mjera za poboljšanje energetske učinkovitosti.

U petom poglavlju izvršena je analiza neovisnih varijabli koje imaju utjecaj na troškove toplinske energije školskih zgrada u FBiH. U cilju razvoja regresijskih modela izvršeno je razdvajanje osnovnog seta podataka na set za razvoj modela (*training set*) i set koji služi za validaciju (*validation set*) regresijskih modela. Postupkom postupne (*stepwise*) regresijske metode unaprijed razvijeni su višestruki linearni regresijski modeli, a za ocjenu istih korištene su neke od statističkih metoda. Početnim razvojem regresijskih modela utvrđeno je kako su ovisne varijable Y_1 (stvarna godišnja isporučena toplinska energija za grijanje zgrada) i Y_2 (stvarni godišnji trošak isporučene toplinske energije) nedovoljno korelirani s neovisnim varijablama pa isti nisu pogodni za razvoj regresijskih modela i što potvrđuje energetski jaz između stvarne i proračunske potrošnje i troškova energije. Zbog navedenog razvoj regresijskih modela za procjenu troškova toplinske energije baziran je na proračunskim vrijednostima potrošnje i troškova toplinske energije. Za ocjenu i rangiranje razvijenih regresijskih modela postavljeni su kriterij reprezentativnosti i kriterij jednostavnosti. Istraživanje pokazuje kako modeli bazirani na specifičnim vrijednostima ovisnih varijabli (vrijednosti svedene na jedinicu korisne površine A_k) daju preciznije procjene (manju pogrešku) i u konačnici bolju predikciju ukupnih proračunskih troškova isporučene toplinske energije za grijanje. Analiza pojedinih neovisnih

varijabli u regresijskim modelima pokazala je kako se neovisne varijable broj stupanj dana grijanja (SDG), godina izgradnje (GI) i faktor oblika (f) pojavljuju se u svih četiriju najbolje rangiranih regresijskih modela.

Tijekom izrade ove doktorske disertacije očekuje se sljedeći znanstveni doprinos:

- Unaprjeđenje kategorizacije školskih zgrada u FBiH identifikacijom skupa karakteristika ili svojstava, potrošnje i troškova toplinske energije školskih zgrada u FBiH koja se temelji na prikupljenim povijesnim podatcima.
- Utvrđivanje temeljnih karakteristika ili neovisnih varijabli školskih zgrada u FBiH, primjenom statističke analize, neophodnih za modeliranje troškova toplinske energije.
- Izrada novih matematičkih modela procjene troškova toplinske energije školskih zgrada u FBiH, u funkciji temeljnih karakteristika zgrada, koji omogućavaju jednostavnije i brže modeliranje troškova toplinske energije u inženjerskoj praksi.

U šestom poglavlju dani su zaključci i smjernice za daljnja istraživanja.

2. Pregled dosadašnjih istraživanja vezanih za troškove uporabe i održavanja zgrada

2.1 Uvod u troškove uporabe i održavanja zgrada

Znanja o modeliranju, analiziranju, projektiranju, održavanju, praćenju, upravljanju, predviđanju i optimizaciji učinaka životnog ciklusa zgrada kontinuirano rastu. Međutim, zgrade nisu unutar željenih razina performansi i sigurnosti a odluke u vezi s njezinim sustavima trebaju biti podržane integriranim višeciljnim okvirom optimizacije životnog ciklusa koji se temelji na pouzdanosti uzimajući u obzir, između ostalih čimbenika, vjerojatnost uspješnog izvođenja i ukupne očekivane troškove koji nastaju tijekom cijelog životnog vijeka zgrade [8].

Pregledom literature i dostupnih radova vezanih za troškove uporabe i održavanja zgrada uočava se kako autori bave različitim aspektima troškova životnog ciklusa kao što su:

- Istraživanje integriranog pristupa u svrhu procijene uštede energije u životnom ciklusu zgrada, smanjenja emisije ugljika i troškovne učinkovitosti mjera energetske učinkovitosti u novim poslovnim zgradama [12],
- Pregled literature iz područja procjene životnog ciklusa (*LCA*), energetske analize životnog ciklusa energije (*Life cycle energy assessment, LCEA*) i analize troškova životnog ciklusa (*Life cycle cost assessment, LCCA*) pokazuje da se većina LCA i LCEA provodi u onome što je prikazano kao "primjerene zgrade", tj. zgrade koje su projektirane i izgrađene kao niskoenergetske, ali postoji vrlo malo studija o ''tradicionalnim zgrada'', poput onih koje se uglavnom nalaze u gradovima [2]. LCEA je verzija LCA koja uzima u obzir samo potrošnju energije u svim fazama životnog ciklusa zgrade i kojom se kvantitativno procjenjuje ukupna energetska učinkovitost zgrade uzimajući u obzir energiju potrebnu za izgradnju i energiju u uporabi zgrade
- Istraživanje u svrhu procjene životnog ciklusa (*LCA*) i projektiranja ciljne vrijednosti (*Target-Value Design, TVD*) kako bi se proizvele održivije zgrade. Korištenjem dinamičkog ažuriranja životnog ciklusa, istraživanje integrirane procjene životnog ciklusa i projektiranja ciljne vrijednosti radi poboljšanja energetske učinkovitosti zgrada i zaštite okoliša pokazuje da zgrade mogu biti projektirane da rade na višim ekološkim standardima od onih koje su projektirane bez cilja [4].
- Istraživanje veze troškova i varijabli koje utječu na njih za što je potrebno stvaranje baze podataka iz koje će se ta veza moći definirati [26].

- Zaključci više istraživača kako je potreba za smanjenjem potrošnje energije najvažniji aspekt za projektiranje energetski učinkovitih zgrada [34].

Stavljanje energetske učinkovitosti predstavlja temeljni izravni ili neizravni pokretač niza ključnih europskih ciljeva, a ključni pristup se temelji na logici da ekonomski optimalne mjere na poboljšanju energetske učinkovitosti zgrada minimiziraju zbroj građevinskih i troškova uporabe (troškovi potrošnje energije) tijekom životnog vijeka trajanja zgrade.

Karakteristike građevinskih dijelova ovojnice zgrade (temelj, krov, zidovi, vrata i prozori), klimatski uvjeti na lokaciji zgrade i razdoblje rada sustava grijanja faktori su koji imaju najveći utjecaj na ukupnu potrošnju energije. Varijable koje također imaju utjecaj na toplinske potrebe zgrade povezane s oblikom zgrade su indeks kompaktnosti, faktor oblika i klima [14].

2.2 Dosadašnja istraživanja o troškovima uporabe i održavanja zgrada

Dosadašnja istraživanja o troškovima životnog ciklusa zgrada pokazala su kako su ukupni troškovi projekata dobro razrađeni u teoriji, ali pri uporabi u praksi nastaju poteškoće. Kao jedna od glavnih zapreka za uspješnu primjenu u praksi navodi se nedostatak korisnih, pouzdanih i konzistentnih podataka potrebnih za procjenu ukupnih troškova projekata. Ako podatci i postoje, ili su nekonzistentni, ili su u obliku koji ne omogućava efikasnu analizu istih. Nedostatak podataka djelomično se objašnjava nedostatkom prihvatljivih standarda u graditeljstvu koji bi definirali način prikupljanja i analizu istih radi planiranja ukupnih troškova projekata [35].

Uporaba i održavanje zgrada (*buildings operation and maintenance*) opisuje se kao skup trajnih aktivnosti koje sadrže tehnička i pridružena im administrativna djelovanja, kako bi se tijekom cijeloga vijeka uporabe zgrade u cjelini i svim njezinim dijelovima osigurala razina služnosti u zadovoljavajućim granicama [36].

Danas se pri planiranju gradnje novih zgrada osim troškova projektiranja i izvođenja u obzir uzimaju i troškovi uporabe, održavanja, zamjene, popravaka i uklanjanja zgrade koji se proračunavaju još u fazi definiranja kada se izrađuje projektna dokumentacija i donose investicijske odluke. Procjenjuju se i analiziraju ukupni troškovi životnog ciklusa projekta (*Whole Life Costs, WLC)* kako bi se donijele optimalne odluke prilikom pokretanja investicija. U literaturi se koriste dva pojma i to troškovi životnog ciklusa (*LCC*) i ukupni životni troškovi (*Whole Life Cycle Costing, WLCC*).

U istraživanju autora Kirkhama tvrdi se da je WLCC evolucija LCC-a, a ne ponovni izum kotača u smislu njegove povezanosti s LCC-om. Mnogi su znanstvenici primijetili da je temeljni problem LCC-a aspekt neizvjesnosti, rizik koji je svojstven budućem predviđanju [25].

1970-tih godina u SAD-u se pojavljuje nova vrste menadžmenta pod nazivom *Facility management* koji u suštini predstavlja gospodarenje, vođenje ili upravljanje građevinama [26]. Facility management je složena interdisciplinarna profesija koja zahtijeva široku bazu znanja, iskustva i kompetencija.

Prema definiciji međunarodnog udruženja za upravljanje građevinama (*The International Facility Management Association*,*IFMA*) upravljanje (gospodarenje) građevinama definira se kao "profesiju koja obuhvaća više disciplina kako bi se osigurala funkcionalnost izgrađenog okoliša integriranjem ljudi, prostora, procesa i tehnologije" [37].

Upravljanje građevinama navodi se kao ključna poslovna funkcija, a upravitelj građevine (*The facility manager*) kao poslovni menadžer koji bi trebao biti postavljen na istu razinu s menadžerima za ljudske odnose i/ili informacijske tehnologije. Upravitelj građevine je stručnjak poduzeća za one čimbenike koji određuju uspjeh posla (proces), za dokumentaciju svih čimbenika i sustava (tehnologija) i zaposlenika (ljudi), kako bi svi oni rasli zajedno. Upravljanje građevinama obuhvaća koncepte isplativosti, produktivnosti, poboljšanja, učinkovitosti i kvalitete života zaposlenika [38].

Razvojem profesija koje su se bavile poslovima upravljanja građevinama došlo je do osnivanja nekoliko profesionalnih udruženja. Među prvima osnovano je inženjering udruženje upravljanja građevinama (*The Association of Facilities Engineering*, *AFE*) i udruženje službenika građevina visokoškolskih ustanova (*The Association of Higher Education Facilities Officers, APPA*). Početkom 1980-ih, institut za upravljanje građevinama (*The Facility Management Institute, FMI*) izdvojio je nacionalno udruženje za upravljanje građevinama (*The National Facility Management Institute, NFMA*). Ubrzo je došlo do pretvaranja NFMA-a u međunarodno udruženje za upravljanje građevinama (*TIFMA*). U svijetu su razvijene udruge kao što su GlobalFM, Safma, EuroFM, MEFMA i druge. Također, razvijale su se udruge ili organizacije na nižim regionalnim ili lokalnim razinama koje nisu međusobno povezane. Općenito, sve ove nastale organizacije ili udruženja pokušavaju informirati i educirati svoje članstvo, pružiti profesionalna imenovanja, istražiti svoja područja stručnosti i održavati mrežne događaje okupljajući svoje članove i dobavljače koji ih uslužuju [38].

Kod proračuna troškova životnog ciklusa projekta postoje dva pristupa. Prvi se bazira na povijesnim podatcima o troškovima (troškovi po metru kvadratnom za slične građevine) i daje vrlo dvojbene rezultate zbog niza faktora. Drugi pristup se bazira na izradi detaljnog modela predviđanja troškova zasnovanog na predviđanju trajnosti, a time i popravaka, održavanja i izmjene konstrukcije ili dijelova konstrukcije, zajedno s troškovima energije. Ovaj drugi način omogućava optimizaciju troškova izgradnje i uporabe te analizu osjetljivosti kojom se utvrđuje koji elementi proračuna su najosjetljiviji na promjene [36].

Prednosti usvajanja koncepta troškova životnog ciklusa posebno su jasne u slučajevima javnih zgrada kojim se promovira rigorozan i jednoznačan okvir pomoću kojeg se analiziraju dugoročni troškovi vlasništva. Proces proračuna troškova životnog ciklusa može se podijeliti u četiri različite komponente [25]:

- planiranje troškova životnog ciklusa (*Life Cycle Cost Planning , LCCP*) je najvažnija komponenta troškova životnog ciklusa čiji je primarni cilj utvrditi sve ukupne troškove koji su uključeni u nabavku i korištenje zgrade,
- ukupni godišnji efektivni troškovi (*Full Year Effect Costs, FYEC*) omogućuju investitoru i projektnom timu razmatranje operativnih i kapitalnih troškova projekata u kraćem vremenskom razdoblju, obično od jedne do tri godine,
- analiza troškova životnog ciklusa (*Life Cycle Cost Analysis, LCCA*) uključuje uspoređivanje i širenje podataka o tekućim troškovima postojećih zgrada, a primarna uloga je identificiranje stvarnih troškova koji nastaju u korištenju građevine i
- upravljanje troškovima životnog ciklusa (*Life Cycle Cost Management, LCCM*) nastavak je prethodnih komponenti kojim se uspostavlja učinkovita politika održavanja zgrade i daju preporuke za učinkovitu uporabu cijele zgrade.

2.3 Životni ciklus zgrade

Životni ciklus zgrade odnosi se na zgradu tijekom cijelog njenog života, odnosno promatrajući zgradu ne samo u uporabi, već uzimajući u obzir i projektiranje, izgradnju, korištenje, rušenje i recikliranje i zbrinjavanje otpada [39]. Upravljanje životnim ciklusom zgrade holistički je poslovni koncept razvijen za upravljanje zgradom i njezinim životnim ciklusom, uključujući materijale, način i kvalitetu izgradnje, analizu rezultata, specifikacije ispitivanja, informacije o utjecaju na okoliš, standarde kvalitete, inženjerske zahtjeve, proizvodne postupke, dobavljače i druge elemente [8].

Na slici 2.1 prikazane su faze ukupnog životnog ciklus za bilo koju građevinu (zgradu):

1. faza planiranja, projektiranja i izgradnje zgrade,
2. faza uporabe i održavanja zgrade i
3. faza kraja životnog vijeka i uklanjanja zgrade.

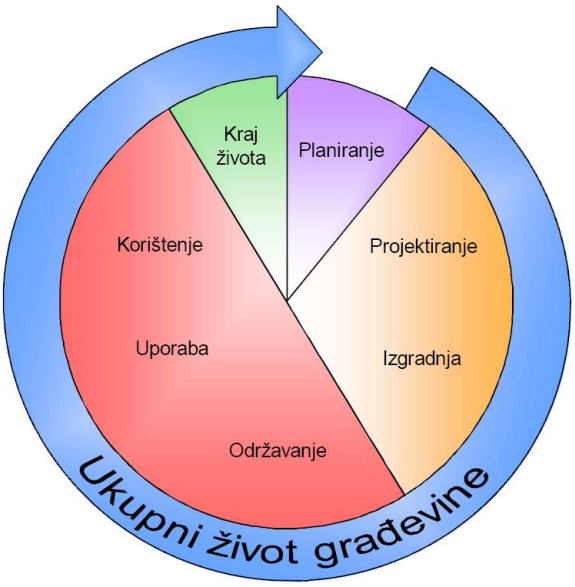

Slika 2.1 Ukupni životni ciklus građevine [40]

U početnoj fazi planiranja, projektiranja i izgradnje zgrade moguć je najveći utjecaj na ukupne životne troškove zgrade jer se u fazi planiranja i projektiranja donose odluke koje će utjecati na sve buduće troškove u idućim fazama životnog ciklusa. Izborom odgovarajućih materijala, konstrukcija, sustava grijanja i hlađenja uz veće početne troškove izgradnje može se značajno utjecati na troškove uporabe i održavanja zgrade u fazi uporabe. Istraživanja su pokazala kako se u fazi projektiranja može utjecati na 70% do 80% troškova uporabe i održavanja [41].

Faza uporabe zgrade najduža je faza u životnim ciklusu izgrađene zgrade. U ovoj fazi uporabe i održavanja provode se aktivnosti koje imaju direktan utjecaj na duljinu životnog vijeka zgrade. Troškovi u ovoj fazi predstavljaju veliki dio troškova životnog ciklusa zgrade i cilj je postići ravnotežu između izdataka za održavanje i troškova održavanja, troškova uporabe i upravljanja i ograničiti rizik neispunjavanja potreba služnosti i sigurnosnih zahtjeva koje zgrada mora ispunjavati.

Dobre prakse upravljanja i održavanja zgrada kroz projekte povećavanja energetske učinkovitosti pokazuju kako se u fazi uporabe postojećih školskih zgrada u SAD-u može uštedjeti do 20% na računima za energiju bez većeg početnog ulaganja. Prilike za uštedu energije kreću se od jednostavnih besplatnih mjera do složenijih i skupljih strategija [42].

Zadnja faza predstavlja kraj životnog vijeka zgrade. Obuhvaća aktivnosti na rušenju, uklanjanju, recikliranju i ponovnom korištenju, i odlaganju otpadnog materijala na deponiju. Također u početnoj fazi planiranja i projektiranja zgrade može se utjecati na troškove uklanjanja zgrade kada ona više ne bude potrebna. U sve faze životnog ciklusa zgrade intenzivno je uključena upotreba i potrošnja prirodnih resursa, energije i vode što ima velikog i dugoročnog utjecaja na prirodu i okoliš.

Na slici 2.2 shematski je prikazana ovisnost mogućnosti smanjenja ukupnih troškova životnog ciklusa zgrade u odnosu na troškove primjene određenih aktivnosti. Na slici se može vidjeti kako je najveća mogućnost uštede troškova životnog ciklusa zgrade u fazi planiranja (koncipiranje i definiranje) bez većih intervencija u projektnoj dokumentaciji uz niske troškove implementacije. Faza projektiranja također omogućuje značajne uštede troškova životnog ciklusa zgrade uz veće troškove implementacije vezane za intervencije na projektnoj dokumentaciji. Mogućnost ostvarivanja ušteda troškova životnog ciklusa zgrade se značajno smanjuje u fazi izvođenja i uporabe zgrade zbog značajnijih intervencija i visokih troškova za implementaciju istih.

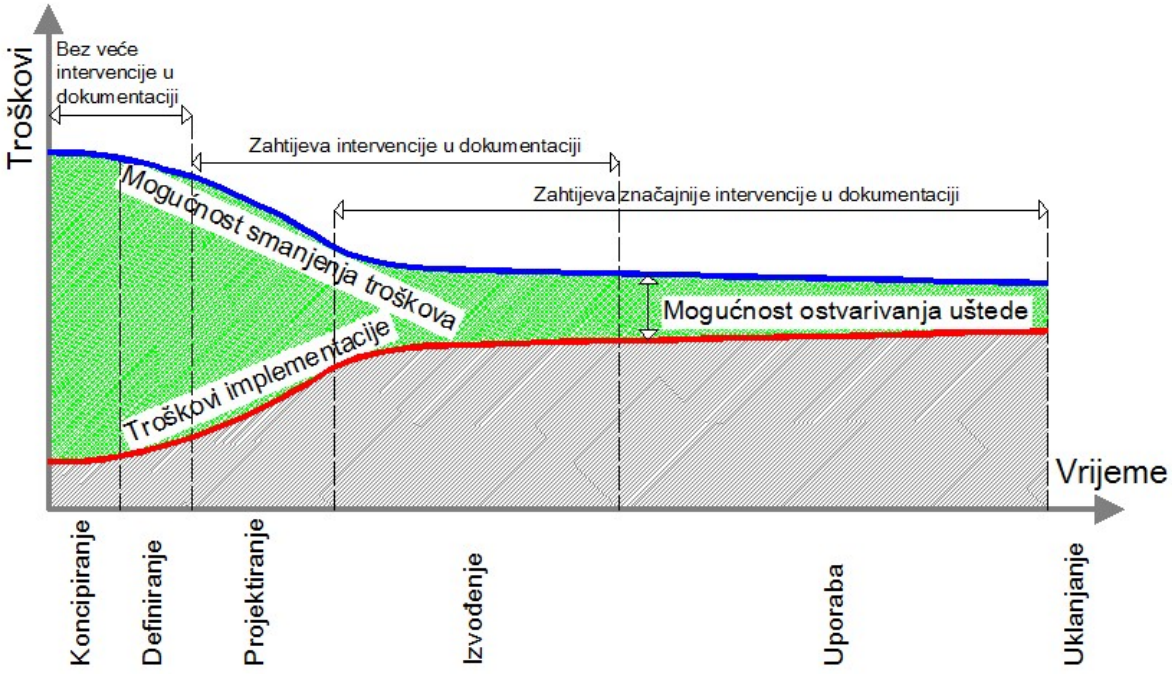

Slika 2.2 Shema ovisnosti smanjenja na troškovima uporabe i održavanja zgrade u odnosu na troškove primjene određenih aktivnosti [26, 43]

2.4 Struktura troškova održavanja i uporabe zgrada

2.4.1 Ukupni troškovi životnog ciklusa

Ukupni životni troškovi (*WLC*) ili troškovi cijelog životnog ciklusa uključuju sve direktne kao i sve indirektne troškove projekta i novčane tijekove i primjenjuje se kod novih i postojećih zgrada. Postoji nekoliko definicija WLC-a. Najosnovnija kaže kako WLC uključuje sustavno razmatranje svih troškova i prihoda povezanih sa stjecanjem, korištenjem, održavanjem i raspolaganjem imovinom [43].

Prema ISO standardu 15686-5:2017 troškovi uporabe i održavanja zgrada dio su troškova životnog ciklusa zgrada i ukupnih životnih troškova zgrada. Ukupni troškovi životnog ciklusa zgrada uključuju

indirektne troškove i prihode zajedno s troškovima životnog ciklusa (izgradnja, uporaba, održavanje i uklanjanje) što je prikazano ma slici 2.3 [41, 44].

Slika 2.3 Struktura ukupnih životnih troškova i troškova životnog ciklusa [41]

Procjena ukupnih troškova služi za ekonomsku i inženjersku procjenu pri izboru alternativnih arhitektonskih rješenja, uspoređujući sve značajne opcije projektiranja, građenja, održavanja i uporabe zgrade tijekom zadanoga vremenskog razdoblja [35]. U tablici 2.1 prikazane su karakteristične troškovne stavke ukupnih životnih troškova i troškova životnog ciklusa.

Tablica 2.1 Karakteristične troškovne stavke ukupnih životnih troškova i troškova životnog ciklusa [26]

R. br.	Struktura		Troškovne stavke
1.	Nekonstrukcijski troškovi		Zemljište Financiranje Upravljanje projektom Naknade Troškovi administracije Porezi Ostalo
2.	Prihodi		Prihodi od prodaje Prihod od treće strane Porezi na prihode Prekidi poslovanja Ostalo
3.	Troškovi životnog ciklusa	Izgradnja	Naknade Projektiranje Pripremni radovi Građenje

			Adaptacija i obnova Porezi Ostalo
		Uporaba	Najam Osiguranje Periodički zakonski troškovi Režije Porezi Ostalo
		Održavanje	Upravljanje održavanjem Adaptacija i obnova tijekom uporabe Manji popravci i izmjene Popravci i zamjene većih sustava Uređenje okoliša Uređenje interijera Čišćenje Porezi Ostalo
		Uklanjanje	Inspekcija Uklanjanje i rušenje Izgradnja ili predaja zemljišta Porezi Ostalo

Građevinarstvo je od nastanka koncepta troškova cijelog životnog ciklusa sporo prihvaćalo i napredovalo prema sveobuhvatnoj i robusnoj metodi procjene dugoročnih troškova vlasništva nad izgrađenim zgradama. Međutim, od 2000-tih godina troškovi cijelog životnog ciklusa postaju široko prepoznati među praktičarima i znanstvenicima kao vrijedan alat u procjeni ekonomske učinkovitosti izgrađenih zgrada [25].

Metoda ukupnih životnih troškova može se primijeniti na dvije razine. Na nižoj razini metoda ukupnih troškova životnog ciklusa koristi se kao ''alat za upravljanje'' koji pomaže u procesu donošenja odluka. Na višoj razini metoda ukupnih troškova životnog ciklusa koristi se kao ''sustav za upravljane'' čiji kontinuirani rad nalaže da se zadrži odgovornost za upravljanje imovinom. Tijekom upravljanja tipičnim projektom u svim fazama, osim faze pokretanja projekta, ova metoda ima potencijalnu uporabu [43].

2.4.2 Troškovi životnog ciklusa zgrada

Troškovi životnog ciklusa (*LCC*) predstavljaju neto sadašnju vrijednost svih relevantnih troškova tijekom cijelog razdoblja zgrade, uključujući troškove izgradnje, troškovi održavanja, popravaka i zamjene, troškove uporabe i preostale vrijednosti [12].

Jedna od najranijih definicija koncepta troškova životnog ciklusa može se uočiti u izvješću Odjela za industriju (UK) iz 1977. godine, koje je uvođenje troškova životnog ciklusa uvelo kao alat u upravljanju imovinom, u kojem su troškovi životnog ciklusa opisani kao ''koncept koji objedinjuje niz tehnika - inženjerskih, računovodstvenih, matematičkih i statističkih - kako bi se uzeli u obzir svi znakoviti neto troškovi koji su nastaju tijekom vlasništva nad imovinom''. Troškovi životnog ciklusa bave se kvantificiranjem opcija za utvrđivanje optimalnog izbora. Omogućuje proučavanje ukupnih troškova životnog ciklusa i kompromisa između troškovnih elemenata tijekom životnih faza imovine i njihovo optimalno korištenje i zamjenu [25].

Osnovna namjena metode troškova životnog ciklusa jeste omogućiti izbor optimalne varijante pri izboru projekta s obzirom na ukupne troškove životnog ciklusa. Primjena je moguća u bilo kojoj fazi projekta, ali je najučinkovitija u početnim fazama planiranja I projektiranja [26].

Na slici 2.4 prikazana je struktura troškova životnog ciklusa zgrade koji nastaju kroz sve životne faze projekta. Troškovi životnog ciklusa obuhvaćaju kapitalne troškove nabavke zgrade (koji nastaju u fazama koncipiranja, definiranja i izvođenja) i buduće troškove uporabe, održavanja i na koncu uklanjanja zgrade. Troškovi životnog ciklusa su ukupni troškovi imovine tijekom uporabnog vijeka, uključujući inicijalne troškove i naknadne uporabne troškove. *LCC* je metoda kojom se između ostalih troškova procjenjuju troškovi uporabe i održavanja građevine i jako je bitna za učinkovito donošenje odluka.

Slika 2.4 Struktura troškova životnog ciklusa [26, 45]

Kapitalni troškovi, odnosno troškovi nabave, u ovisnosti o namjeni buduće zgrade, uvijek predstavljaju značajan udio u ukupnim troškovima životnog ciklusa. Ovi troškovi se odnose na 1. fazu životnog ciklusa zgrade, i predstavljaju ukupne troškove vezane za nabavku zemljišta, projektiranje, izgradnju i opremanje zgrade i ostale druge troškove koji se odnose na aktivnosti u fazi planiranja, projektiranja i izgradnje zgrade (na slici 2.5 prikazana je struktura kapitalnih troškova).

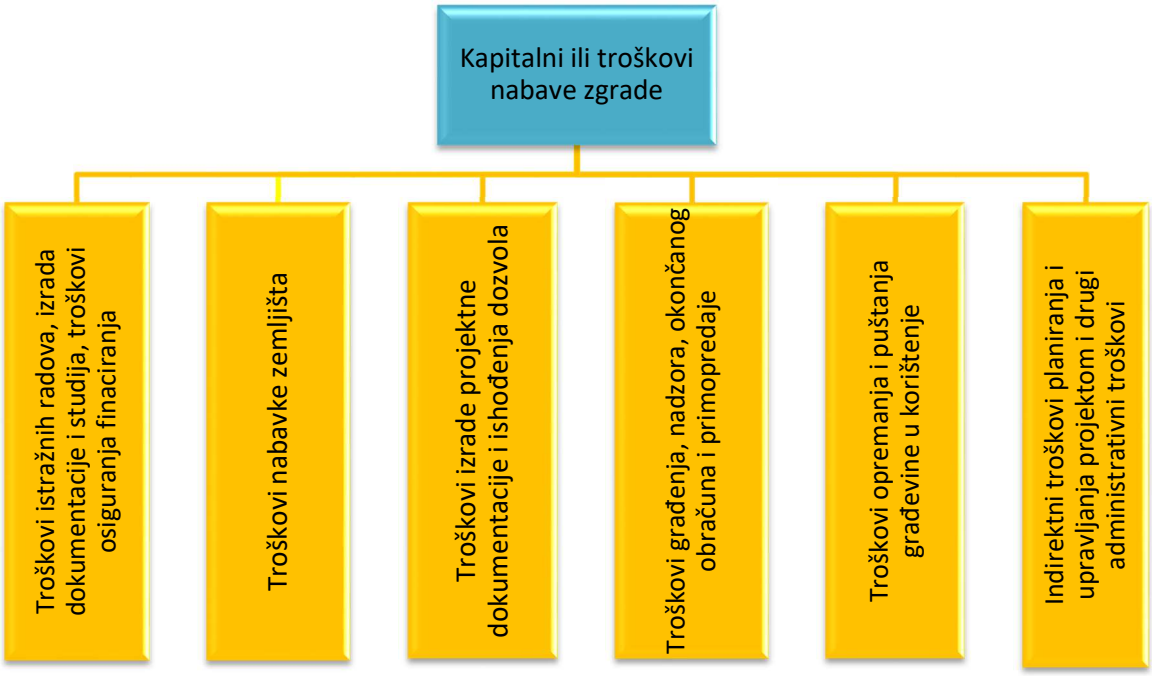

Slika 2.5 Struktura kapitalnih troškova [35, 45]

Početni kapitalni troškovi projekta uglavnom su oni koji se najviše uzimaju obzir od strane naručitelja i projektnog tima u studijama izvodljivosti građevinskog projekta, a u nedostatku procjene ukupnih troškova predstavljaju vrijednost koja će najvjerojatnije odrediti hoće li projekt započeti ili ne [25].

Budući ili uporabni troškovi se odnose na 2. i 3. fazu životnog ciklusa zgrade. Troškovi uporabe su troškovi koji se javljaju tijekom cijelog uporabnog vijeka zgrade. Troškovi održavanja su troškovi koji „drže“ zgradu u funkcionalnom stanju, odnosno to su troškovi koji se javljaju nakon određenog vremenskog razdoblja kojima se određeni element vraća u prvobitno stanje. Ključno je precizno predviđanje i planiranje budućih troškova.

U troškove uklanjanja zgrade uključena je preostala ili prodajna vrijednost zgrade kao i troškovi koji nastaju za radove rušenja, uklanjanja i čišćenja zemljišta (gradilišta) na kraju predviđenog vijeka trajanja zgrade. Ovdje su uključeni i svi indirektni troškovi koji nastaju u ovoj fazi [35].

Do nedavno troškovi zgrade obuhvaćali su samo kapitalne troškove vezane za stjecanje vlasništva nad zemljištem, troškove projektiranja, ishođenja dozvole za gradnju te troškova izgradnje zgrade. U novije vrijeme sve se više govori i razmatraju se budući troškovi vezani za fazu uporabe, odnosno troškovi koji će se pojaviti nakon puštanje zgrade u uporabu [36].

Budući troškovi životnog ciklusa uključuju troškove održavanja, uporabe i uklanjanja zgrade. Prema ISO standardu 15686-5:2017 troškovi održavanja (*maintenance cost*) zgrada obuhvaćaju troškove potrebnog rada, materijala i ostale povezane troškove koji se javljaju pri održavanju određene razine uslužnosti neke zgrade. Tu pripadaju troškovi nastali za provođenje korektivnog, reaktivnog i preventivnog održavanja na zgradi ili njenim dijelovima, a uključuju sva povezana upravljanja, čišćenja, servisiranja, bojanja, popravaka i zamjena dijelova, ako je potrebno, kako bi se izgrađena zgrada mogla koristiti za namjeravane svrhe [44].

Održavanje zgrada je niz aktivnosti kojima se postiže da izgrađene zgrade omogućuju adekvatnu uporabu i funkcionalnost za namjenu za koju su projektirane. Zakonska regulativa u Bosni i Hercegovini i zemljama okruženja na sličan način definira pojam održavanje građevine. Prema uredbi o tehničkim svojstvima koje građevine moraju zadovoljavati u pogledu sigurnosti te načina uporabe i održavanja građevina ("Službene novine Federacije BiH", br. 29/07, 51/08 i 99/14) održavanje i korištenje građevine mora biti takvo da se u predviđenom vremenu njezinog trajanja očuvaju tehnička svojstva bitna za građevinu kojima se ne mijenja usklađenost građevine s urbanističko-tehničkim uvjetima, u skladu s kojima je građevina izvedena, s tim da se njenim korištenjem ne ugrožava život i zdravlje ljudi, okolice, prirode, drugih građevina i stvari, niti stabilnost tla na okolnom zemljištu. Također, vlasnik građevine, odnosno korisnik dužan je održavati građevinu na način da se njenim održavanjem

osigurava upotrebljivost i ispravnost građevine, uređaja i opreme, upotrebljivost građevine kao cjeline i sigurnost njenog uporabe [46].

Iz gore navedenog proizlazi kako je potrebno definirati dopustive granice razina služnosti i utvrditi tzv. standarde održavanja elemenata, sklopova i građevina. Standardima se određuje donja dopustiva kvaliteta koju zbog trošenja ili starenja element, koju sklop i građevina mogu imati, tako da budu zadovoljeni svi bitni uvjeti zgrade (stabilnost, zaštita od požara, zaštita od buke, zaštita od gubitka topline), svi bitni funkcionalni uvjeti za uporabu (svjetlo, grijanje, hlađenje, čišćenje) te estetski uvjeti (izgled podova, zidova, stropova, kvaliteta pojedinih elemenata) [47].

Pri projektiranju zgrada potrebno je napraviti dio projektne dokumentacije (projekt održavanja) koji se odnositi na održavanje tijekom uporabnog vijeka iste i se sastoji od [47]:

1. *Opisa standarda* kojim se određuje donja dopustiva kvaliteta koju zbog trošenja i/ili starenja trebaju imati elementi, sklopovi i ostali dijelovi zgrade.
2. *Opisa i utvrđivanja radova na održavanju* za što je potrebno poznavati uzroke kvarova i potrebne mjere sanacije koje će odgovarati u danom trenutku.
3. *Procjene troškova održavanja* pri čemu se koriste prijašnja iskustva u održavanju istih ili sličnih zgrada, a ukoliko takvo iskustvo ne postoji onda se mora osloniti na procjenu. Ovaj dio je veoma osjetljiv jer se na osnovu procjene troškova održavanja temelji investitora politika održavanja.
4. *Planiranja radova* kojim se definira vremenski početak i kraj pojedine aktivnosti održavanja zgrade.
5. *Organizacije izvedbe radova* kojom se utvrđuje izvedbe radova. Potrebno je donijeti odluku da li će se s nekim poduzećem ugovoriti održavanje zgrade na određeno vremensko razdoblje, ili će se angažirati neki neovisan izvoditelj od kvara do kvara.
6. *Kontrola troškova i kvalitete*, kontrola predviđenih troškova i kontrola ostvarene kvalitete koja se vrjednuje na osnovi prethodno definiranih standarda.

Radovi redovitog održavanja zgrade podrazumijevaju radove koji ne utječu na konstrukciju zgrade, zaštitu okoline, namjenu, promjenu dimenzija i vanjskog izgleda (manji popravci, žbukanje, bojenje pročelja i njihovo dovođenje u prvobitno stanje, zamjena i bojenje građevne stolarije, ostakljivanje postojećih otvora, pokrova, manjih dijelova krovne konstrukcije, zidanje pregradnih zidova, zamjena i opravka oštećenih instalacija, zidanje porušenih dimnjaka i sl.), odnosno, kojima se ne mijenjaju uvjeti utvrđeni urbanističkom suglasnošću i odobrenjem za gradnju [48].

Održavanje zgrada može se podijeliti na preventivno održavanje odnosno planirano održavanje na temelju projekta održavanja i reaktivno održavanje, odnosno hitno ili nepredvidivo održavanje. Preventivno održavanje može biti bazirano na vremenu ili stanju istrošenosti pojedinih elemenata. Obuhvaća zamjenu istrošenih materijala i elemenata, zakonom propisane periodične preglede, radove i popravke. Zakonom propisani periodični pregledi uključuju niz aktivnosti koje su propisane važećim zakonima i propisima u svrhu poduzimanja mjera za određenu vrstu zgrada karakteristične namjene koja je neophodna za osiguranje zdravlja, života i sigurnosti ljudi [41].

Zakonom propisani periodični pregledi ili inspekcijski pregledi uključuju niz aktivnosti koje su propisane važećim zakonima i propisima za određenu vrstu građevine karakteristične namjene. Provode se u određenim vremenskim intervalima. Ovdje se ubrajaju neke od mogućih aktivnosti i troškova koji nastaju provedbom navedenih aktivnosti [36, 45]:

- ispitivanje hidrantske instalacije,
- ispitivanje sustava za dojavu požara,
- ispitivanje vatrogasnih aparata,
- ispitivanje i pregled gromobranske instalacije,
- mjerenje otpora izolacije električnih vodiča,
- pregled i ispitivanje električnih instalacija,
- ispitivanje ispravnosti panik rasvjete,
- pregled klimatizacijskih uređaja,
- deratizacija i dezinsekcija,
- ispitivanje kotlovnice i
- obveza posjedovanja energetskog certifikata.

Periodični planirani radovi i popravci su one aktivnosti koje se ponavljaju u relativno jednakim vremenskim intervalima radi zadržavanja definirane razine služnosti zgrade [26]. Vremenski intervali pojavljivanja periodičnih radova određen je temeljem iskustva, te po potrebi odnosno pri nastajanju eventualne štete. Troškovi periodičnih radova i popravaka, odnosno troškovi preventivnog održavanja, nastaju poduzimanjem nekih od mogućih aktivnosti [36, 41, 45]:

- bojanje zidova i stropova,
- bojanje fasade,
- zidarski popravci žbuke,
- bojanje zidova hodnika uljanom bojom,
- bojanje radijatora,

- bojanje ograde stubišta,
- bojanje vanjske i unutarnje stolarije,
- bojanje metalnih konstrukcija i
- brušenje i bojanje podova.

Troškovi zamjene istrošenih materijala i elemenata obuhvaćaju troškove aktivnosti baziranih na ostvarenim izmjenama pojedinih dotrajalih materijala i elemenata zgrade [41]. Kod planiranja zamjene istrošenih materijala i elemenata koriste se podatci o prosječnom vjerojatnom vijeku trajanja pojedinih materijala ili elemenata zgrade. Ovdje se ubrajaju neke od mogućih aktivnosti zamjene istrošenih materijala [36, 45]:

- zamjena pokrova zgrade,
- zamjena slojeva ravnog krova,
- zamjena limenih dijelova zgrade (opšavi isl.),
- zamjena vertikalnih i horizontalnih dijelova oborinske odvodnje,
- zamjena vanjskih otvora,
- zamjena unutarnjih otvora,
- zamjena opreme za grijanje,
- zamjena instalacija vodovoda i kanalizacije,
- zamjena sanitarnih uređaja,
- zamjena elektroinstalacija i opreme,
- zamjena telefonskih instalacija i opreme,
- zamjena instalacija slabe struje i opreme,
- zamjena klima uređaja,
- zamjena vatrodojave,
- zamjena podova (parketa, keramičkih pločica),
- zamjena zidnih i podnih keramičkih pločica i
- zamjena ograde.

Reaktivno održavanje zgrade predstavlja popravke i zamjene materijala tek nakon što je nastupio kvar ili oštećenje i zbog navedenog gotovo je nemoguće predvidjeti sve kvarove, a samim tim i troškove. Kako je velik broj mogućih aktivnosti na popravcima i zamjenama elemenata i materijala u sklopu intervencija tako je i raspon troškova reaktivnog održavanja vrlo teško predvidjeti [41]. Ovdje se ubrajaju neke od mogućih aktivnosti vezanih za reaktivno održavanje [36, 45]:

- zamjena žarulja i fluo cijevi,

- ostakljenje razbijenih staklenih površina,
- popravci vatrodojave,
- popravci prozora i vrata,
- popravak krova i limarski radovi,
- popravak podova,
- popravci gipskartonskih zidova ili obloga,
- popravci ili zamjene sanitarnih uređaja,
- popravci ili zamjena telefonskih uređaja i instalacija,
- popravci ili zamjena klima uređaja i instalacija,
- popravci ili zamjena uređaja, opreme i instalacija za grijanje,
- popravci ili zamjena uređaja, opreme i instalacija za ventilaciju,
- održavanje kanalizacijskih i vodovodnih instalacija i
- održavanje elektro instalacija i opreme.

U buduće troškove osim troškova održavanja uključeni su i troškovi uporabe zgrade koji se definiraju kao troškovi nužni za korištenje zgrade i uključuju pogonske troškove opskrbe energentima (električna energija, toplinska energija, energija za hlađenje i ventilaciju prostora), troškove opskrbe pitkom vodom, troškovi plina, troškove odvoza komunalnog otpada i otpadnih voda, režijske troškove telefona, interneta, TV-a, troškove čišćenja i higijene, te druge slične troškove [26, 41]. Troškovi uporabe mogu prekoračiti kapitalne troškove građevine i nekoliko puta u tijeku uporabnog vijeka. Na slici 2.6 prikazana je ukupna struktura budućih troškova zgrade.

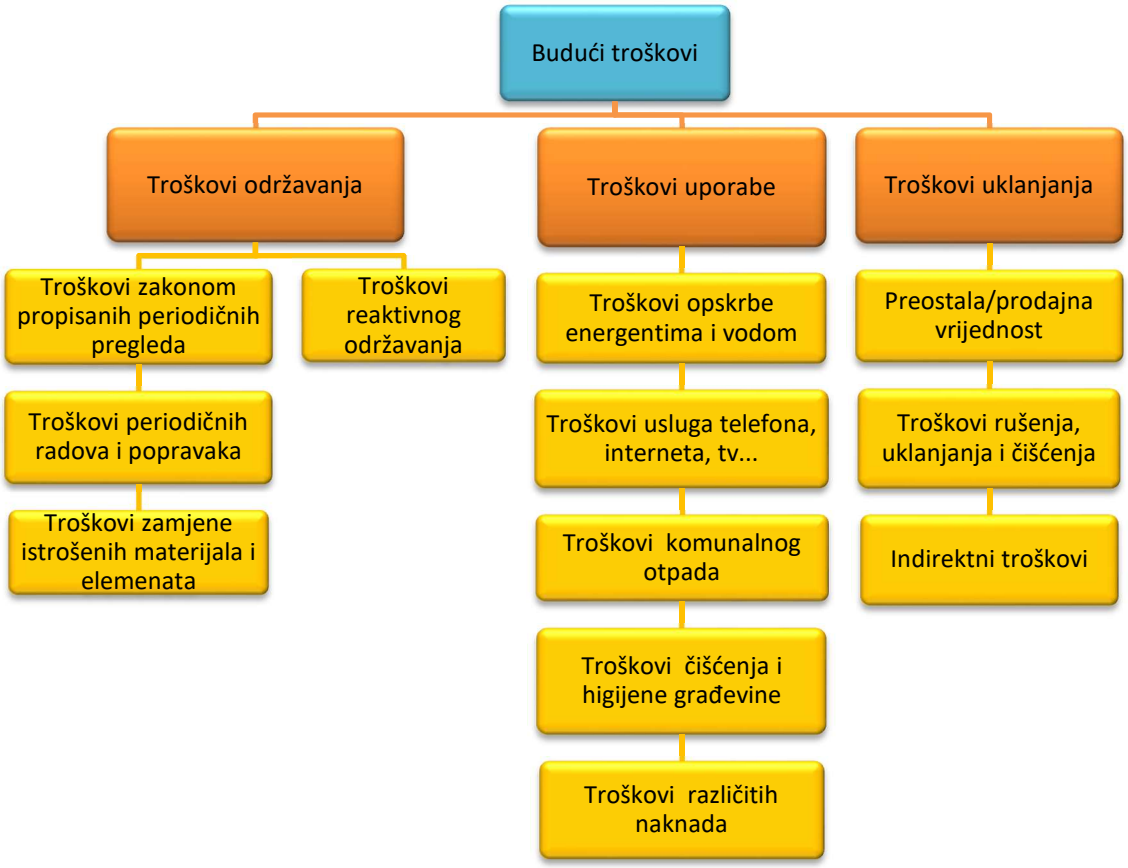

Slika 2.6 Struktura budućih troškova zgrade [35, 41]

Prema ISO standardu 15686-5:2017 troškovi uporabe (*operation cost*) su troškovi nastali korištenjem i upravljanjem zgradom ili izgrađenim okolišem, uključujući usluge administrativne podrške. Ovi troškovi mogu uključivati rente, kamate, osiguranja, energiju i ostale troškove inspekcije zaštite okoliša ili regulatornih propisa, lokalne poreze i naknade i slično [44].

Troškovi uporabe mogu sadržavati sljedeće troškovne stavke [36, 45]:

- opskrba električnom energijom,
- opskrba toplinskom energijom,
- opskrba pitkom vodom,
- telefonske, internet i tv usluge,
- odvoz komunalnog otpada,
- čišćenje i higijena građevine i okoliša,
- komunalna naknada i
- ostale naknade (osiguranja, kamate…).

Troškovi životnog ciklusa (*LCC*) predstavljaju sadašnju vrijednost svih trenutnih i budućih troškova izgradnje zgrade, te uporabe i održavanja iste tijekom životnog vijeka. Ovakav pristup omogućava analizu mogućih ušteda u fazi uporabe zgrade koje je moguće ostvariti različitim scenarijima i aktivnostima u fazi planiranja i izgradnje zgrade.

Ako se metoda troškova životnog ciklusa provodi na već postojećoj zgradi troškovi inicijalnog kapitalnog ulaganja ne uzimaju se u obzir. No, za nove projekte i projekte s kraćim životnim vijekom oni mogu činiti velik dio troškova životnog ciklusa i klijentima analize biti će potrebno pokazati posljedice, prednosti i mane nižih ili viših inicijalnih kapitalnih troškova [2].

Prema vodiču za analizu troškova životnog ciklusa (*Guidelines for Life Cycle Cost Analysis*) potrebno je izvršiti usporedbu troškova u odnosu na 6 općih kategorija [49]:

- energetski sustavi vezani za postrojenja i opremu za proizvodnju energije,
- mehanički sustavi vezani za distribuciju,
- električni sustavi vezani za rasvjetu, automatiku i upravljanje,
- ovojnica zgrade vezana za izbor materijala i toplinske zaštite,
- položaj zgrade u odnosu na strane svijeta, zaklonjenost, visinu i druge elemente i
- konstruktivni sustavi vezani za izbor materijala za nosivu konstrukciju zgrade.

Osnovni cilj metode troškova životnog ciklusa je osiguranje kvalitetne i precizne metode procjene ukupnih troškova zgrade. Ova metoda zamjenjuje tradicionalne metode bazirane na procjeni inicijalnih troškova te daje odgovor na pitanje je li projekt troškovno opravdan, odnosno jesu li troškovi životnog ciklusa minimalni između mogućih alternativnih rješenja.

Prednosti primjene metode troškova životnog ciklusa se mogu prepoznati u javnom sektoru (iskazivanje vrijednosti nabave novca, smanjenje troškova uporabe, mogućnost planiranja budućih troškova), privatnom sektoru (smanjenje troškova uporabe, olakšano planiranje troškova), komercijalnom sektoru (privlačenje kupaca kroz poznati trošak nad nekretninama, očuvanje vrijednosti nekretnine) i javno-privatnom partnerstvu (mogućnost planiranja budućih troškova, smanjenje troškova uporabe). Istraživanjem u doktorskom radu autora Krstića navode se prednosti uporabe metode troškova životnog ciklusa [26]:

- transparentnost budućih troškova uporabe, održavanja i uklanjanja,
- mogućnost detaljnijeg planiranja budućih troškova uporabe i održavanja,
- proračun i prikaz ukupnih životnih troškova zgrade,
- mogućnost optimalizacije troškova u početnoj fazi projekta kada je efikasnost najveća,
- postizanje veće vrijednosti novca,

- usklađivanje sa zahtjevima javne nabave,
- odabir optimalne strategije izbora projektnog rješenja ili nabave,
- mogućnost ocjene novih materijala i tehnologija i utjecaja na ukupne troškove,
- utvrđivanje troškovno značajnih stavki troškova životnog ciklusa i
- mogućnost kontrole i usporedbe planiranih troškova i postignutih svojstava zgrade.

Unatoč nabrojanim prednostima i mogućnostima koje primjena metode troškova životnog ciklusa omogućava s druge strane postoje znatna ograničenja i prepreke u primjeni iste [25, 26]:

- praksa prihvaćanja najjeftinije ponude odnosno najnižih kapitalnih troškova bez ikakvog interesa za njezinu budućnost nakon razdoblja odgovornosti za nedostatke,
- nedostupnost pouzdanih i prikladnih ulaznih podataka o troškovima i životnim vjekovima materijala i konstrukcija,
- nepostojanje zajedničke metodologije, pristupa i mjerenja,
- poteškoće pri definiranju određenih troškova,
- koncept "budućnosti se ne može predvidjeti" pokriva koncepte koštanja životnog ciklusa,
- ograničena suradnja između kupaca i dobavljača,
- projektanti skloni da ne brinu previše o *LCC-u*, a posebno o optimizaciji troškova jer se njihove naknade gotovo uvijek izračunavaju kao postotak od ukupne ugovorne cijene,
- loša kvaliteta podataka dobavljača i nedostatak iscrpnih podataka o uporabnim uvjetima proizvoda,
- loša izrada ili materijali glavni su uzroci za troškove popravaka ,
- troškovno i vremenski zahtjevna metoda,
- zahtjevan posao prikupljanja podataka za analizu,
- odvojenost proračuna za izgradnju i održavanje u javnom sektoru,
- nedostatak znanja naručitelja o prednostima pristupa životnog ciklusa, što dovodi do subjektivnog donošenja odluka,
- nedostatak potpore javnog sektora i
- glavni problem nedostatak odgovarajućih ili upotrebljivih podataka.

U osnovi LCC filozofije su troškovi uporabe i održavanja. Budući da se mnoge odluke u fazi projektiranja temelje isključivo na početnim kapitalnim troškovima nasuprot budućih troškova, prilično je lako razumjeti zašto se LCC nije razvio na način koji to zaslužuje [25].

Ideja da se troškovi životnog ciklusa mogu kontrolirati i minimizirati široko je privlačna, ali upravljanje troškovima životnog ciklusa ne primjenjuje se dosljedno u fazi projektiranja i izgradnje. Dva su glavna problema koja obeshrabruju uporabu troškova životnog ciklusa. Jedan je nedostatak pouzdanih podataka o povijesnim troškovima zgrada koji su potrebni za točnu procjenu troškova, a drugi je činjenica da ne postoji učinkovita metoda kontrole *LCC-a* [50].

2.5 Matematički modeli za proračun troškova životnog ciklusa

Analiza postojećih matematičkih modela troškova životnog ciklusa pokazuje da je većina zasnovana na metodi neto sadašnje vrijednosti, a razlikuju se u nomenklaturi i strukturi troškova [41]. Pregledom literature mogu se naći jednostavniji ili složeniji matematički modeli proračuna troškova životnog ciklusa, a u nastavku će se prezentirati neke od njih. Jedan od jednostavnijih matematičkih modela za proračun troškova životnog ciklusa ima sljedeći oblik [25]:

$$LCC = I_C + O_C + M_C + R_C \tag{2.1}$$

gdje su:

- LCC troškovi životnog ciklusa,
- I_C inicijalni kapitalni troškovi,
- O_C troškovi uporabe,
- M_C troškovi održavanja i
- R_C preostala vrijednost zgrade.

Iako ovaj model izgleda vrlo jednostavno, sastavni dijelovi zahtijevaju mnogo složenog prikupljanja i organizacije podataka. U osnovi bi ovu jednadžbu bilo vrlo teško koristiti bez pristupa potpuno sveobuhvatnoj bazi podataka. Vrijeme provedeno u prikupljanju ovih podataka može se pokazati skupim i u konačnici pretjeranim [25].

Američko društvo građevinskih inženjera (*American Society of Civil Engineers, ASCE*) razvilo je model sličan prethodnom u kojem su izdvojeni troškovi uporabe energije [25]:

$$LCC = C_C + R_C - S_C + A_C + M_C + E_C \tag{2.2}$$

gdje su:

- LCC troškovi životnog ciklusa,
- C_C inicijalni kapitalni troškovi investicije,
- R_C kapitalni troškovi zamjene materijala ili elemenata,

- S_C tržišna vrijednost zgrade na kraju promatranog razdoblja,
- A_C godišnji troškovi uporabe, održavanja i popravaka,
- M_C periodični troškovi održavanja i
- E_C troškovi uporabe energije.

Jedan složeniji i generički model za prikupljanje podataka i proračun ukupnih troškova životnog ciklusa, primjenljiv na elemente zgrade i ukupnu zgradu, predlažu El-Haram i ostali [51]:

$$WLC = C_C + \left(\sum_{i=1}^{n} \left(\sum_{j=1}^{m} O_{Cj} \right) + \sum_{i=1}^{n} \left(\sum_{j=1}^{m} M_{Cj} \right) + \sum_{i=1}^{k} R_{Ci} \right) \pm D_C \tag{2.3}$$

gdje su:

- WLC ukupni troškovi životnog ciklusa,
- C_C kapitalni troškovi,
- O_C troškovi uporabe,
- M_C troškovi održavanja,
- R_C troškovi zamjene istrošenih materijala,
- D_C troškovi uklanjanja zgrade,
- n broj godina ili očekivani životni vijek,
- m broj troškovnih elemenata ili stavki i
- k broj elemenata za zamjenu ili obnovu.

Ukupni nediskontirani troškovi projekta ili zgrade mogu se izračunati prema sljedećem izrazu [35]:

$$UTP_P = Ti_P + Tfm_P \pm Tr_p \tag{2.4}$$

gdje su:

- UTP_P ukupni troškovi projekta (zgrade različitih namjena: bolnice, škole…),
- Ti_P inicijalni ili kapitalni troškovi projekta,
- Tfm_P troškovi ''facility managementa'' na razini projekta i
- Tr_P troškovi rušenja ili uklanjanja na razini projekta.

Stohastički matematički model za proračun ukupnih troškova cijelog životnog ciklusa (*WLCC*) razvijen je i prikazan u doktorskom radu autora Kirkhama iz 2002. godine za postojeće bolničke zgrade u UK.

Model se temelji na informacijama o godišnjoj distribuciji vjerojatnosti koje u Monte Carlovom simulacijskom modelu predviđaju WLCC distribucije vjerojatnosti na izlazu. Utvrđeno je da inverzna Gaussova raspodjela najbolje predstavlja WLCC model. Formalno, WLCC model izražava se kao [25]:

$$WLCC = \sum_{i=1}^{n} \frac{FM_C + E_C + M_C + F_C + R_C}{(1+r)^i} \tag{2.5}$$

gdje su:

- $WLCC$ ukupni troškovi životnog ciklusa,
- FM_C troškovi gospodarenja (upravljanja) građevinom,
- E_C troškovi uporabe energije,
- M_C troškovi održavanja,
- F_C troškovi financiranja,
- R_C preostala vrijednost zgrade,
- r diskontna stopa i
- i broj godina promatranog razdoblja.

Osim navedenih metoda za proračun ukupnih troškova životnog ciklusa pregledom literature se nalaze metode koje su razvijane za proračun pojedinih komponenti ukupnih troškova, odnosno najčešće za proračun troškova uporabe i održavanja zgrada određenih namjena.

1999. godine razvijen je model za predviđanje ukupnih troškova energije sportskih centara u Liverpoolu koristeći regresijske metode. Rezultati ispitivanja i validacije pokazali su visoku razinu točnosti modela. Model ima dva (2) oblika i koristi dvije nezavisne ulazne varijable (površina zgrade i broj korisnika) i ograničen je na sportske zgrade [26, 52]:

$$C_E = 1,203 + 0,97 \cdot površina \tag{2.6}$$

$$C_E = 1,217 + 0,642 \cdot površina + 0,206 \cdot korisnici \tag{2.7}$$

gdje su:

- C_E ukupni troškovi energije sportskih centara.

U radu Al-Hajj i Hornera opisuje se razvoj i ispitivanje nove metode koja smanjuje količinu podataka za prikupljanje bez neprihvatljivog smanjenja korisnosti. Temelji se na principu značajnosti troškova (troškovno značajnih stavki) kako bi se iz rijetkog i dosljednog skupa podataka za dvadeset (20) zgrada na Sveučilištu York stvorio jednostavan model troškova uporabe i održavanja (zajedno nazvani tekući

troškovi). Utvrđeno je kako oko 15% troškovnih stavki predstavlja oko 85% ukupnih troškova uporabe i održavanja. Konačni model odabire se mjerodavnim faktorom modela troškova (CMF faktor modela troškova predstavlja odnos troškova troškovno značajnih stavki prema ukupnim troškovima) koji ima najmanji koeficijent varijacije. Model za proračun ukupnih troškova uporabe održavanja može se napisati u sljedećem obliku [23]:

$$R_C = \frac{1}{CMF}\sum_{i=1}^{n}\left[\left(c_1 + c_2\right) + \left(e_1 + e_2 + e_3\right) + \left(a_1 + a_2\right) + \left(o_1 + o_2\right) + \left(m_1 + m_2\right)\right] \tag{2.8}$$

gdje su:

- R_C ukupni troškovi uporabe i održavanja,
- CMF faktor modela troškova,
- c_1 troškovi čišćenja,
- c_2 troškovi praonice rublja,
- e_1 troškovi plina,
- e_2 troškovi električne energije,
- e_3 troškovi lož ulja,
- a_1 troškovi naknada za upravljanje,
- a_2 troškovi zaštitarskih službi osiguranja,
- o_1 troškovi kamata,
- o_2 troškovi osiguranja,
- m_1 troškovi unutarnjeg uređenja,
- m_2 troškovi popravaka krova i
- n broj godina.

Istraživanjem u doktorskom radu autora Krstića koje se odnosilo na razvoj modela za procjenu troškova održavanja i uporabe na primjeru zgrada Sveučilišta Josipa Jurja Strossmayera u Osijeku usvojena su dva modela. Prvim modelom se računaju godišnji nominalni troškovi uporabe [26]:

$$PGNTU = 313041{,}00 - 230{,}48 \cdot P_S - 208{,}51 \cdot P_U + 3047{,}94 \cdot D_{PR} \tag{2.9}$$

gdje su:

- $PGNTU$ prosječni godišnji nominalni troškovi uporabe,
- P_S površina sanitarnih prostora,

- P_U površina uredskih prostorija i
- D_{PR} prosječni broj djelatnika tijekom promatranog vremenskog razdoblja.

Navedeni model daje vrijednosti prosječnih godišnjih nominalnih troškova uporabe koji su jednaki za svaku godinu tijekom promatranog vremenskog razdoblja. Također, moguće je odrediti i procijenjene neto sadašnje vrijednosti troškova uporabe zgrada, odnosno diskontirane troškove uporabe. Usvojeni model je model s jednom varijablom i odnosi se na procjenu troškova održavanja i uporabe. Izraz prema kojemu se računaju procijenjeni godišnji nominalni troškovi održavanja i uporabe glasi [26]:

$$PGNTOiU = 379184 + 762,09 \cdot P_{KOM} \tag{2.10}$$

gdje su:

- $PGNTOiU$ prosječni godišnji nominalni troškovi održavanja i uporabe i
- P_{KOM} površina komunikacija.

Može se zaključiti kako su svi gore prikazani modeli kojima se proračunavaju troškovi uporabe i održavanja namijenjeni su za određenu vrstu i namjenu zgrade te da ne postoji univerzalni model koji bi mogao biti primjenljiv na sve tipove zgrada.

Svi se modeli oslanjaju u određenoj mjeri na pretpostavke, bile one eksplicitne ili implicitne. Da bi se procijenio održivost modela, korisnik mora imati pristup i razumjeti pretpostavke koje mu pridonose. Izbor modela trebao bi se temeljiti na sljedećim karakteristikama [52]:

- značajke podataka koje će se koristiti - kvantitativne, kvalitativne, veliki broj, mali broj,
- opće znanje o problemu koji treba modelirati,
- općenito znanje o graničnim uvjetima modela,
- pogreške koje model može generirati,
- ulazni i izlazni ciljevi i moguće posljedice i
- razumijevanje točnosti, pouzdanosti, valjanosti, pouzdanosti i osjetljivosti odabranog modela.

Vrijednosti troškova trebale bi biti izražene što preciznije. Pri proračunu troškova stavki koje imaju velik utjecaj na sveukupne troškove potrebno je posebno voditi računa o njihovoj točnosti. Za svaki trošak, bio to samo element troškova ili cijela kategorija troškova, potrebno je odrediti vremensko razdoblje kada će do toga troška doći kako bi se mogla provesti analiza troškova životnog ciklusa. Troškovi bi trebali biti iskazani u njihovoj sadašnjoj vrijednosti. Računalni modeli troškova trebali bi biti izraženi u parametarskom obliku, što znači svaki trošak bi trebalo vezati za parametar koji, ako promijenjen, utječe na promjenu svih troškova vezanih uz taj parametar [25].

U istraživanju autora Kishka i ostalih zaključuje se da je za provođenje analize troškova životnog ciklusa identificirano pet kategorija podataka [43]:

- ekonomske varijable koje uključuju diskontne stope, utjecaj inflacije, vremensko razdoblje ili okvir,
- podatci o troškovima uključuju početne inicijalne troškove, troškove uporabe, održavanja i popravka, troškove zamjene elemenata, troškove rušenja i ostale troškove,
- podatci o načinu uporabe, a s obzirom na namjenu zgrade, uključuju podatke o uvjetima uporabe i režimu rada koji utječu troškove uporabe,
- fizički podatci o zgradi odnose se na fizičke dijelove zgrada koji se mogu izmjeriti (poput površina podnih i zidnih završnih obloga) i ovi podatci su neophodni u svim metodama procjene troškova i
- podatci o izvedbi i kvaliteti utječu na izbor politike održavanja, no međutim podatci koji se odnose na kvalitetu vrlo su subjektivni dok su podatci o izvedbi često nepotpuni, difuzni i uglavnom nestrukturirani.

Troškovi životnog ciklusa zgrade sastoje se od određenog iznosa novca uloženog u različitim vremenskim trenutcima. Stoga je za izračunavanje troškova životnog ciklusa pogrješno zbrajati nominalnu vrijednost tih troškova kako i kada se pojave. Kako bi se troškovi koji se javljaju u različitim vremenskim razdobljima pretvorili u zajedničku osnovu, koristi se koncept sadašnje vrijednosti kojim se budući troškovi diskontiraju na sadašnju vrijednost. Kao rezultat učinaka zarađenih kamata, sadašnja vrijednost novčanih tokova manja je od njihove buduće vrijednosti i niža je što je vremenski iznos duži. Izraz za metodu diskontiranja [7]:

$$P_n = \frac{T_n}{(1+r)^n} \tag{2.11}$$

gdje su:

- P_n sadašnja vrijednost,
- T_n budući troškovi,
- r kamatna stopa i
- n broj godina.

Na slici 2.7 grafički su prikazani podatci potrebni za analizu troškova životnog ciklusa zgrade. Oni uključuju podatke o načinu uporabe zgrade, podatke o fizičkim karakteristikama zgrade, podatke o strukturi i kvaliteti zgrade i njenih elemenata, podatke o korisnicima i financijske podatke o zgradi [53].

Slika 2.7 Podatci potrebni za analizu troškova životnog ciklusa [53]

2.6 Pregled udjela pojedinih troškova životnog ciklusa

U prethodnom poglavlju prikazani su opći modeli kojima se proračunavaju troškovi životnog ciklusa kao i modeli za procjenu troškova uporabe i održavanja namijenjenih za određenu vrstu i namjenu zgrada. U nastavku su prikazani primjeri udjela pojedinih troškova životnog ciklusa na temelju dosadašnjih istraživanja i pregleda literature.

Troškovi uporabe razlikuju se prema različitim vrstama zgrada i namjene. Prema studiji *Joint Center for Land Development* za poslovne zgrade opći rasponi pojedinačnih troškova prikazani su kao postotak od ukupnih troškova životnog ciklusa kako slijedi [7]:

- 7-30% troškovi održavanja,
- 15-45% troškovi potrošnje energije,
- 5-40% troškovi čišćenja,
- 5-45% troškovi financiranja (kamate),
- 2-20% troškovi osiguranja i
- 0-10% troškovi osiguravanja i upravljanja.

Svi gore navedeni podatci odnose se na godišnje troškove jednako distribuirane tijekom uporabe zgrade.

Rezultati studije koja se odnosila na proračun troškova životnog ciklusa (*LCC*) za 25-godišnje razdoblje apartmanske zgrade (8 katova, 203 apartmana, ukupne površine 16.719 m^2) sveučilišta Atma Jaya Yogyakarta (*Universitas Atma Jaya Yogyakarta*) u Indoneziji pokazuje sljedeći odnos ukupnih troškova životnog ciklusa [54]:

- 41,7 % inicijalni kapitalni troškovi (troškovi izgradnje),
- 39,3 % troškovi uporabe i
- 19,0 % troškovi održavanja.

Unutar troškova uporabe najveći udio se odnosi na administrativne troškove (troškove vezane za administraciju i osoblje koje upravlja zgradom) u iznosu od 40,6%, zatim troškovi potrošnje vode od 35,8%, troškovi potrošnje električne energije 17,5% a preostali dio se odnosi na ostale troškove [54].

U istraživanju troškova životnog ciklusa (*LCC*) za 10-godišnje razdoblje provedenom na dijamantnoj zgradi (*Diamond Project Building*) u Maleziji izvršeni su izračuni nekih aspekta troškova kao što su inicijalni troškovi, troškovi energije, troškovi uporabe i održavanja te troškovi zamjene materijala ili elemenata. Rezultati istraživanja pokazuju sljedeći odnos ukupnih troškova životnog ciklusa [55]:

- 62,4 % inicijalni kapitalni troškovi,
- 20,5 % troškovi uporabe, održavanja i zamjene materijala i
- 17,1 % preostala vrijednost.

Studija o LCC-u provedena na zgradi hostela Jimbun Medika u Kediriju u Indoneziji za 25-godišnje razdoblje pokazuje sljedeći odnos ukupnih troškova životnog ciklusa [56]:

- 46 % inicijalni kapitalni troškovi,
- 26 % troškovi uporabe i
- 28 % troškovi održavanja.

Također u Indoneziji je za sveučilišne zgrade Atma Jaya Yogyakartas napravljena LCC studija za 25-godišnje razdoblje čija je svrha bila utvrditi omjer LCC troškova i napraviti dugoročne planove. Rezultati studije pokazuju sljedeći odnos ukupnih troškova životnog ciklusa [57]:

- 43 % inicijalni kapitalni troškovi,
- 46 % troškovi uporabe i
- 11 % troškovi održavanja.

Usporedba rezultata za 3 studije koje se odnosile na proračun troškova životnog ciklusa (*LCC*) za 25-godišnje razdoblje za zgrade različitih namjena smještenih u Indoneziji prikazana je u tablici 2.2.

Tablica 2.2 Usporedba troškova životnog ciklusa (*LCC*) za 3 studije [54]

Zgrada/namjena	Inicijalni troškovi (%)	Troškovi uporabe (%)	Troškovi održavanja (%)
Hostel Jimbun Medika	46	26	28
Sveučilišne zgrade Atma Jaya Yogyakartas	43	46	11
Apartmanska zgrada sveučilišta Atma Jaya Yogyakarta	42	39	19
Prosjek	43,7	37,0	19,3

Analizirajući prosječne vrijednosti glavnih komponenata (inicijalne troškove, troškove uporabe i troškove održavanja) troškova životnog ciklusa zgrada različitih namjena (*LCC*) za 25-godišnje razdoblje smještenih u Indoneziji može se zaključiti kako pojedinačno inicijalni (kapitalni troškovi vezano za izgradnju zgrade) troškovi imaju najveći udio od oko 43,7%. Promatrajući zajedno troškove uporabe i održavanja koji nastaju u fazi uporabe zgrade njihov udio zajednički iznosi oko 56,3% što je više u odnosu na početne kapitalne troškove.

Flanagan i Norman (1989.) su istraživali troškove uporabe i održavanja uredskih poslovnih zgrada u Velikoj Britaniji. Procijenili su da se na svakih potrošenih 100 funti za otplatu kapitalnih troškova izgradnje potroši 138 funti na tekuće troškove uporabe i održavanja. Također, Flanagan i Norman (1983) identificirali su pet komponenata povezanih s ukupnim troškova životnog ciklusa (*LCC*) uredskih poslovnih zgrada za 40-godišnje razdoblje [33]:

- 42 % troškovi za otplatu kapitalnih troškova,
- 20 % troškovi čišćenja,
- 16 % troškovi kamata,
- 12 % troškovi održavanja i
- 10 % troškovi za energiju.

U knjizi pod nazivom ''Održivi život: uloga i vrijednosti troškova cijelog života'' koja se temelji na rezultatima studije pojedinačnih kuća u relativno blagoj klimi regije Aucklanda u Novom Zelandu demonstriraju se implikacije izbora koje projektanti i korisnici zgrada mogu napraviti kako bi postigli veću održivost u sektoru stambenih zgrada kroz analizu koja pokriva puni životni vijek kuće. Knjiga također pokazuje praktičnu uporabu analize životnog ciklusa za postizanje najbolje prakse u gradnji i korištenju stambenih zgrada. Dan je primjer udjela pojedinih troškova u ukupnim životnim troškovima klasičnih obiteljskih kuća, ako se troškovi životnog ciklusa diskontiraju sa stopom od 5%, tada je raspodjela troškova životnog ciklusa sljedeća [7]:

- 56% inicijalni kapitalni troškovi (troškovi izgradnje),
- 16% troškovi održavanja i
- 28% troškovi grijanja i rasvjete.

Od istraživanja koja su se odnosila na troškove uporabe i održavanja zgrada u BiH i zemljama okruženja, istraživanje u doktorskom radu autora Krstića na primjeru 8 zgrada Sveučilišta Josipa Jurja Strossmayera u Osijeku, pokazuje sljedeće vrijednosti ukupnih godišnjih nominalnih troškova uporabe i održavanja [26]:

- ukupni prosječni godišnji nominalni troškovi uporabe iznose 493.135,00 EUR (1 HRK = 0,132 EUR prema srednjem tečaju i tečajnoj listi HNB-a na dan 26.10.2020.) i
- ukupni prosječni godišnji nominalni troškovi održavanja i uporabe iznose 1.178.026,00 EUR.

Može se zaključiti kako za 8 zgrada Sveučilišta Josipa Jurja Strossmayera u Osijeku udio ukupnih prosječnih godišnjih nominalnih troškova uporabe u odnosu na ukupne prosječne godišnje nominalne troškovi održavanja i uporabe iznosi oko 42%. Ako se ukupni prosječni godišnji nominalni troškovi uporabe podijele s ukupnom korisnom površinom analiziranih zgrada tada specifični prosječni godišnji nominalni troškovi uporabe iznose 14,29 EUR/m^2.

Novčana jedinica Bosne i Hercegovine je “konvertibilna marka” (KM). Prema službenom tečaju Centralne banke Bosne i Hercegovine odnos eura i konvertibilne marke je fiksan i jedan euro iznosi 1,95583 konvertibilnih maraka. Prilikom konverzije novčanih jedinica konvertibilnih maraka u eure u ovom radu koristiti će se navedeni odnos.

U diplomskom radu izrađenom 2018. godine izvršena je analiza troškova održavanja i uporabe javne zgrade Studentskog centra u Mostaru za razdoblje od 25 godina svedenih na neto sadašnju vrijednost (NPV) s diskontnom stopom od 3,00 % prikazana je u tablici 2.3.

Tablica 2.3 Troškovi održavanja i uporabe javne zgrade Studentskog centra u Mostaru [45]

Troškovi	Neto sadašnja vrijednost (NPV) EUR	Udio (%)
1. Troškovi održavanja	543.746,00	16,50
1.1 Troškovi zakonom propisanih periodičnih pregleda	53.863,00	1,63
1.2 Troškovi periodičnih radova i popravaka	257.947,00	7,83
1.3 Troškovi zamjene istrošenih materijala i elemenata	75.039.00	2,28
1.4 Troškovi reaktivnog održavanja	156.897,00	4,76
2. Troškovi uporabe	2.751.089,00	83,50
Ukupni troškovi (EUR):	3.294.835,00	100,00

U ukupnim troškovima održavanja i uporabe javne zgrade Studentskog centra u Mostaru za razdoblje od 25 godina najveći udio maju troškovi uporabe zgrade u udjelu od 83,50%. U ukupnoj strukturi troškova uporabe najveći udio imaju troškovi koji se odnose na troškove opskrbe električnom energijom u djelu od 27,5%, zatim troškovi održavanja soba, vešeraja, kotlovnice i solara od 23,3%, troškovi opskrbe toplinskom energijom 16,2%, troškovi opskrbe pitkom vodom 10,4%. Ostale kategorije troškova uporabe imaju udio manji od 10% [45].

Specifični prosječni godišnji troškovi uporabe zgrade Studentskog centra u Mostaru iznose 24,07 EUR/m^2. Prosječni specifični godišnji troškovi potrošnje toplinske energije iznose 5,85 EUR/m^2 a prosječni specifični troškovi električne energije 6,63 EUR/ m^2 [45].

Prema podatcima iz vodiča (*A Guidebook for K-12 School System Business Officers and Facilities Managers*) tipični školski okrug u USA prosječno godišnje plaća oko 1,00 USD po četvornoj stopi za troškove energije. Prevedeno na kvadratne metre (1 m^2=10,764 ft^2) to bi iznosilo oko 10,76 USD/m^2, odnosno 9,15 EUR/m^2 (1 USD = 0,85) [42].

Pregledom literature i istraživanja koja prezentiraju udjele pojedinih komponenti (strukture) troškova životnog ciklusa može se zaključiti sljedeće:

- autori istraživanja uglavnom prezentiraju parcijalne vrijednosti udjela pojedinih komponenti troškova životnog ciklusa s aspekta dostupnih raspoloživih podataka za zgrade različitih namjena i za različita vremenska razdoblja tako da se prikazani podatci ne mogu uspoređivati i
- iz dostupnih istraživanja koja sadrže podatke o strukturi ukupnih troškova životnog ciklusa može se vidjeti kako su ukupni troškovi uporabe i održavanja zgrada za promatrano vremensko razdoblje veći od početnih kapitalnih troškova vezanih za izgradnju zgrade.

2.7 Pregled potrošnje toplinske energije

Pregledom literature i istraživanja vezanih za potrošnju toplinske energije nalaze se različiti načini prikazivanja potrošnje toplinske energije, različiti pristupi i metodologije proračuna, i različite jedinice mjerenja ovisno o zemlji i zakonskim propisima što dovodi do jedva usporedivih vrijednosti. Na europskoj razini države članice Europske unije imaju različite certifikate o energetskoj učinkovitosti koji iskazuju različite podatke na različitim skalama. Sličan se proces odvija u SAD-u i Kanadi [27].

Fond stambenih zgrada izgrađenih prije 1970-ih u Europskoj uniji koji čini više od 3/4 ukupnih postojećih stambenih zgrada ima nisku razinu energetskih karakteristika u pogledu uštede energije. Glavni problem velike potrošnje energije postojećih zgrada koje su izgrađene prije nekoliko desetljeća jeste u nezadovoljavanju trenutačnih zahtjeva energetske učinkovitosti prema važećem

zakonodavstvu. Prosječni toplinski gubitci u stambenim zgradama iznose od 180-250 kWh/m^{2}god. Značajan udio takvih zgrada i dalje će se koristiti još mnogo godina, a ukoliko se energetski učinkovito ne obnove, oni će i dalje nepotrebno trošiti velike količine energije. Stoga energetska obnova tih zgrada ima veliki potencijal za smanjenje potrošnje energije, a time i smanjenje emisije CO_2 [58].

Potrošnja energije u školama se može okarakterizirati različitim pokazateljima učinkovitosti, ovisno o nekoliko parametara, kao što su tipologija (namjena) škole (vrtić, osnovna ili srednja škola) koja odražava različite rasporede aktivnosti i uporabe. Zatim tu su geometrijske karakteristike zgrade i razdoblje izgradnje koji utječu na potrošnju energije. Nove škole imaju manju potrošnju energije u usporedbi s zgradama izgrađenim za vrijeme nepostojanja energetskih propisa vezanih za toplinsku zaštitu [59].

Na potrošnju toplinske energije utječe više faktora [33]:

- sastav konstrukcije i način izgradnje zgrade,
- zgrade imaju svojstveno visoku potrebu za energijom,
- neučinkoviti sustavi grijanja, hlađenja i ventilacije, te loša kontrola i upravljanje nad istim,
- neadekvatno ili loše izvedeno održavanje,
- nepotrebno korištenje usluga,
- broj dnevnih sati grijanja i ponašanje korisnika u zgradama i
- klimatski uvjeti.

U nastavku dan je prikaz potrošnje toplinske energije na temelju dostupnih podataka pregledom literature sa posebnim naglaskom na školske zgrade. U tablici 2.4 prikazana je tipična potrošnja energije za razne tipove zgrada u Velikoj Britaniji preuzeta iz dokumenta izrađenog 1988. godine kojeg je izradila Komisija za audite [33].

Tablica 2.4 Pokazatelji potrošnje energije u Velikoj Britaniji [33]

Vrsta ili tip zgrade	Potrošnja energije (kWh/m^{2}god)
Osnovne škole	200-300
Srednje škole	205-295
Uredski prostori površine do 200 m^2	200-400
Sportski centri bez bazena	210-350
Visokoškolske zgrade	210-350
Rekreacijski centri s bazenom (površina bazena manja od 20% ukupne površine centra)	900-1400
Bazeni (površina bazena veća od 20% ukupne površine)	1250-1750
Stambene kuće	350-800

Prema Diasu Pereiri i ostalima godišnje vrijednosti potrošnje energije za grijanje školskih zgrada u europskim zemljama variraju od oko 52 do 197 kWh/m^2 [27]. Uobičajena godišnja potrošnja energije za grijanje iznosi 96 kWh/m^2 za Irsku [60], za Sloveniju varira od 112 kWh/m^2 godišnje do 196 kWh/m^2 [61], 157 kWh/m^2 za Veliku Britaniju [29] i približno 100 kWh/m^2 za središnju Italiju [62]. U slovenskim školama potrošnja energije veća je u usporedbi sa susjednim zemljama, a stvarna potrošnja energije je manja u odnosu na potrebnu dobivenu proračunom [61].

Istraživanje provedeno na 80 školskih zgrada (koje karakteriziraju različite značajke i tehnologije izgradnje) smještenih u središnjoj Italiji (regija Lazio) pokazuje da prosječna godišnja vrijednost specifične toplinske energije za grijanje iznosi oko 23 kWh/m^3 [59]. Također, istraživanje stvarne potrošnje toplinske energije za grijanje provedeno na oko 140 zgrada namijenjenih za obrazovanje u regiji Torino pokazuje prosječnu godišnju vrijednost od 38 kWh/m^3, uz pretpostavku visine etaže od 3m, navedena vrijednost odgovara 115 kWh/m^2 [63].

Istraživanje provedeno nad 76 školskih zgrada smještenih u sjevernoj Italiji, u provinciji (okrugu) Milano, i podatcima prikupljenim iz dokumenata energetskog pregleda pokazuje da prosječna godišnja vrijednost specifične toplinske energije za grijanje iznosi 47 kWh/m^3 [64]. Usporedbom navedene vrijednosti s istom u regiji Lazio (23 kWh/m^3) dolazimo do zaključka da je specifična prosječna godišnja toplinska energija u sjevernoj Italiji oko 2 puta veća, gdje su klimatski čimbenici najvjerojatniji razlog za takav odnos.

Prosječna godišnja potrošnja primarne energije portugalskih škola u 2012. godini iznosila je 67 kWh/m^2, od čega se 16 kWh/m^2 odnosilo na uporabu plina, a 51 kWh/m^2 odnosilo se na uporabu električne energije [65].

Prema podatcima iz 1995. godine prosječna godišnja potrošnja toplinske energije u grčkim školskim zgradama, u različitim klimatskim regijama, iznosi oko 92 kWh/m^2 grijanog prostora, ali u mnogim slučajevima doseže 100, pa čak i do 200 kWh/m^2 grijanog prostora. Prema rezultatima istraživanja iz 2007. godine u grčkim školama prosječna godišnja potrošnju energije iznosi 95 kWh/m^2 raspoređena između 68 kWh/m^2 za grijanje i 27 kWh/m^2 za električnu energiju [66].

U studiji izrađenoj nakon 2010. godine u Luksemburgu analizirana je potrošnja energije 68 školskih zgrada gdje prosječna godišnja potrošnja toplinske energije iznosi 93 kWh/m^2 dok prosječna godišnja potrošnju električne energije iznosi 32 kWh/m^2 [67].

Istraživanje provedeno u južnoj Finskoj vezano za potrošnju toplinske energije u postojećim zgradama namijenjenih za obrazovanje (gdje je broj stupanj dana grijanja 3645 °C·d) pokazuje da najčešća godišnja vrijednost potrošnje toplinske energije u školskim zgradama iznosi 214 kWh/m^2 [68].

Studija izrađena na 8 različitih osnovnih škola u alpskim regijama Tirola s različitim razdobljima izgradnje pokazuje za postojeće stanje prosječnu godišnju potrošnju toplinske energije u iznosu od 104 kWh/m^2. Izrađena je troškovno optimalna analiza za planirane mjere energetske obnove koja pokazuje da je optimalna neto sadašnja vrijednost troškova za potrošnju toplinske energije grijanja u rasponu od 50 do 60 kWh/m^2. Nadalje, pokazuje se da razdoblje gradnje najviše utječe na rezultate neto sadašnje vrijednosti [69].

Analizirajući gore navedene primjere potrošnje toplinske energije u školskim zgradama može se uočiti heterogenost u načinu prikazivanja, različitih metodologija proračuna, i različitih jedinica mjerenja ovisno o zemlji što onemogućuje usporedbu i ukazuje na potrebu za razvoj zajedničkog pristupa mjerenja i proračuna koji bi bili usporedivi. Navedeni podatci služit će za okvirnu usporedbu sa stvarnom potrošnjom toplinske energije u školskim zgradama FBiH.

2.8 Zaključna razmatranja o troškovima životnog ciklusa

Metoda troškova životnog ciklusa (*LCC*) predstavlja najčešće korištenu metodu koja služi kao alat za donošenje odluka, prvenstveno izbora alternativnih projektnih rješenja sa stajališta ukupnih troškova projekta. Međutim, u praksi se javljaju i druge tehnike i metode koje imaju za cilj različite aspekte ili faze životnog ciklusa projekta.

Jedna od tehnika kojom se procjenjuje utjecaj na okoliš u svim fazama života proizvoda od vađenja sirovine, obradu materijala, proizvodnju, distribuciju, korištenje, popravak i održavanje, te odlaganje ili recikliranje naziva se procjena životnog ciklusa (*LCA*). LCA je kvantitativna procjena uporabe resursa (sirovine i energija) i stvaranja otpada za svaki korak života proizvoda, usluga, aktivnosti i tehnologija čime se pruža način za procjenu i kvantificiranje utjecaja na okoliš. Osnovni ciljevi LCA su [7]:

- usporedba alternativnih procesa ili rješenja,
- poboljšanje učinkovitosti uporabe resursa,
- procjena utjecaja na okoliš,
- utvrđivanje načina smanjenja utjecaja na okoliš i
- služi kao izvor informacija o korištenju resursa i emisijama u okoliš.

Iako je LCA moćan alat za procjenu utjecaja na okoliš, on zapravo ne rješava sve dvojbe niti olakšava proces odabira i nije metoda za donošenje odluka [34]. S obzirom na složenost odnosa između građenja i prirodnog okoliša procjena životnog ciklusa (*LCA*) predstavlja sveobuhvatan pristup ispitivanju utjecaja ukupne izgradnje na okoliš. Brojne studije procjene životnog ciklusa istražile su utjecaje izgrađenih zgrada na održivost okoliša. Postignut je konsenzus o tome da se većina energetskog i ugljičnog utjecaja životnog ciklusa nastaje tijekom faze uporabe zgrada [4].

Razlika između metode procjena životnog ciklusa (*LCA*) i metode troška životnog ciklusa (*LCC*) je u tome što je cilj LCA uspoređivanje različitih alternativnih rješenja sa stajališta ekoloških performansi radi zadovoljavanja iste funkcije krajnje uporabe, iz široke društvene perspektive, dok LCC ima za cilj utvrditi isplativost alternativnih ulaganja i poslovnih odluka iz perspektive donositelja ekonomskih odluka, kao što je proizvodna tvrtka ili potrošač [70]. LCC i LCA omogućuje projektnim timovima da pokažu da su za odabrana varijantna rješenja razmotrili utjecaje na okoliš i ekonomiju te u konačnici odabrali najprikladnije materijale/proizvode [8].

Energija životnog ciklusa (*Life Cycle Energy, LCE*) predstavlja ukupnu energiju koja se pripisuje zgradi tijekom njezinog životnog vijeka. Ovo je kvantitativna metoda analize koja se rabi za utvrđivanje energetskih utjecaja zgrada na okoliš. Energija životnog ciklusa sastoji se od energije potrošene prilikom izgradnje i od operativne energije koja se troši u fazi uporabe zgrade [7].

Projektiranje ciljne vrijednosti (*TVD*) je tehnika ciljanog troška koja se primjenjuje na građevinske projekte. Rabi se u fazi projektiranja i izgradnje kako bi se potaknuli projektanti koji trebaju osigurati vrijednosti za kupca unutar ograničenja projekta. TVD pruža „integriranu“ metodu za olakšavanje procesa procjene troškova zajedničkog životnog ciklusa (*LCC*) povećavanjem razine zajedničkog razumijevanja i komunikacije među sudionicima u projektu [4].

Ova metodologija određivanja ciljeva za životni ciklus u fazi projektiranja može se primijeniti u projektiranju održive ciljne vrijednosti (*Sustainable Target Value,STV*) utjecaja na okoliš, korištenjem LCA i cijelog životnog vijeka TVD-a, u projektiranju zgrada u nastojanju da se znatno više grade ekološki održive zgrade. Cilj projektiranja STV je smanjenje utjecaja na okoliš zgrada tijekom njihovog životnog ciklusa postavljanjem ciljeva za okolišne pokazatelje u fazi projektiranja. Odabrani pokazatelji su primarna energija i potrošnja vode kao glavni resursi koji se koriste u fazi izgradnje. Veliki izazov nastaje u određivanju kako postaviti ciljeve. Dok su podatci o troškovima izgradnje prevladavajući i standardizirani, podatci o ekološkoj učinkovitosti zgrada su ograničeni i neprecizni [4].

U vodiču pod nazivom ''Uporaba i održavanje škola: Najbolji postupci za kontrolu troškova energije'' (*School Operations and Maintenance: Best Practices for Controlling Energy Costs*) navodi se da je uz strategije za održavanje zgrada moguće i smanjenje troškova energije i povećanje energetske učinkovitosti u postojećim školama, bez obzira na starost zgrade. Ovaj vodič pruža detaljne i praktične smjernice o tome kako školske uprave u USA mogu planirati i implementirati poboljšanja svojih trenutnih programa za uporabu i održavanje koji mogu uspješno održavati svoje zgrade, a istovremeno smanjiti troškove energije do 20% [42].

Pregledom literature s područja troškova životnog ciklusa i postojećih modela troškova održavanja i uporabe zgrada može se zaključiti sljedeće [41]:

- najveći dio ukupnih životnih troškova zgrada čine troškovi održavanja i uporabe,
- postojeći modeli troškova životnog ciklusa i modeli održavanja i uporabe zgrada većinom se ne temelje na povijesnim podatcima o troškovima zgrada,
- modeli koji se temelje na povijesnim podatcima o troškovima zgrada uglavnom su razvijeni na osnovi dostupne strukture troškova, a ne na osnovi definirane strukture troškova,
- ne postoje baze podataka o troškovima koje bi se mogle rabiti za buduća istraživanja ili ažurirati radi unapređenja postojećih modela,
- ne postoji okvir za sistematizaciju podataka i
- ne postoje jednostavni modeli koji pri izračunu troškova održavanja i uporabe uzimaju u obzir neke od karakteristika zgrada ili načina uporabe.

Zaključna razmatranja o troškovima životnog ciklusa zgrada:

- u teoriji su dobro razvijeni matematički modeli za procjenu ukupnih troškova životnog ciklusa a razlikuju se u nomenklaturi i strukturi troškova,
- u primjeni troškova životnog ciklusa zgrada nastaju poteškoće zbog nedostataka korisnih i pouzdanih podataka vezanih za sve faze životnog ciklusa, posebice za fazu uporabe i održavanja,
- dosadašnja istraživanja troškova životnog ciklusa pokazuju da su ukupni troškovi uporabe i održavanja zgrada za promatrana vremenska razdoblja veći od početnih kapitalnih troškova vezanih za izgradnju zgrade i zbog navedenog bitno je precizno analizirati troškove uporabe i održavanja naročito u početnim fazama planiranja projekta kada je moguć najveći utjecaj na smanjenje ukupnih troškova i
- modeli troškova životnog ciklusa zgrada ne povezuju karakteristike zgrada sa troškovima životnog ciklusa.

3. Prikupljanje i obrada podataka

3.1 Pregled stanja i zakonodavnog okvira u BiH

U Bosni i Hercegovini podatci o potrošnji energije ne prikupljaju se sustavno od strane službene državne institucije i nisu objedinjeni na jednom mjestu. Istraživanja pokazuju da preko 50% ukupne potrošnje energije u Bosni i Hercegovini se odnosi na sektor zgradarstva [71]. Na slici 3.1 prikazana je struktura potrošnje energije u Bosni i Hercegovini.

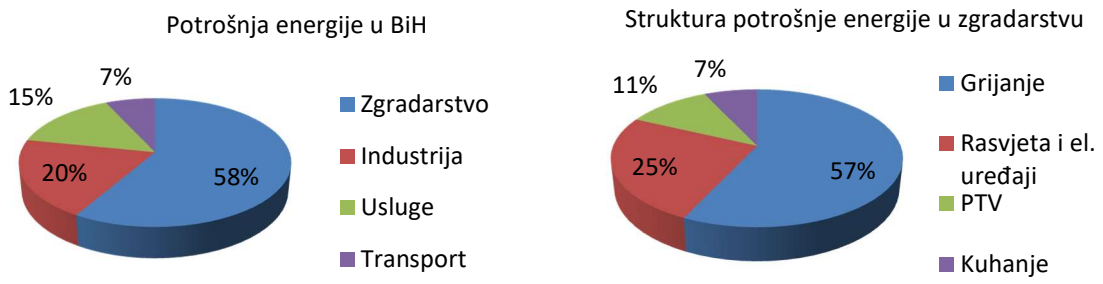

Slika 3.1 Struktura potrošnje energije u Bosni i Hercegovini [72]

U ciklusu proizvodnje, distribucije i potrošnje energije u Bosni i Hercegovini se ostvaruju veliki gubitci. Ista količina energije ostvaruje četiri puta manje nacionalnog proizvoda nego u prosječnoj zemlji EU uz duplo više zagađenja [73]. Potrošnja toplinske energije u BiH je dosta visoka u usporedbi s razvijenim zemljama zbog velikog broja zgrada izgrađenih u prethodnom razdoblju bez ili sa vrlo malom toplinskom zaštitom (razdoblje prije 2009. godine kada je stupio na snagu novi propis o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije). Procjena je da prosječna potrošnja toplinske energije u zgradarstvu u BiH iznosi preko 180,00 kWh/m^{2}god.

Kako su zgrade najveći pojedinačni potrošači energije [72] pokrenute su aktivnosti za razvoj i planiranje strategija i planova energetske obnove zgrada. Kao preduvjet formiranja strategije smanjenja potrošnje energije neophodno je bilo kreirati tipologiju stambenog i nestambenog fonda zgrada u Bosni i Hercegovini čime bi se lakše mogli definirati akcijski planovi energetske obnove i sagledavati efekti istih. Članstvom u Energetskoj zajednici Bosna i Hercegovina je također preuzela obavezu izrade tipologije stambenih i nestambenih zgrada.

Bosna i Hercegovina je jedna od zemalja ne Europske unije koja je potpisala ugovor o osnivanju Energetske zajednice 2005. godine. Ovaj ugovor obvezuje sve ugovorne zemlje između ostalog da preuzmu i implementiraju odgovarajuće direktive i uredbe Europske unije iz područja energetske učinkovitosti i zaštite okoliša. Ključni dijelovi EU energetskog zakonodavstva su direktive 2006/32/EC, direktiva 2010/31/EC i direktiva 2012/27/EU. Direktivom 2012/27/EU uspostavlja se zajednički okvir

mjera za poticanje energetske učinkovitosti kako bi se osiguralo ostvarivanje krovnog cilja povećanja energetske učinkovitosti [74].

Energetska politika uključuje planiranje i osmišljavanje učinkovitih rješenja multidisciplinarnog pristupa kako bi se odredila optimalna rješenja. Temelj za izradu strategija i politike energetske učinkovitosti je uređenje zakonskog okvira kroz donošenje zakona o energetskoj učinkovitosti i pratećih propisa.

Bosna i Hercegovina je država koja ima složen ustroj i se sastoji od dva entiteta, Federacije Bosne i Hercegovine [FBiH] i Republike Srpske [RS], te Brčko distrikta Bosne i Hercegovine [BD BiH] kao zasebne upravne jedinice (slika 3.2). Navedeno uzrokuje sporost u implementaciji preuzetih obveza kao i izradi i provedbi akcijskih planova vezanih za energetsku učinkovitost.

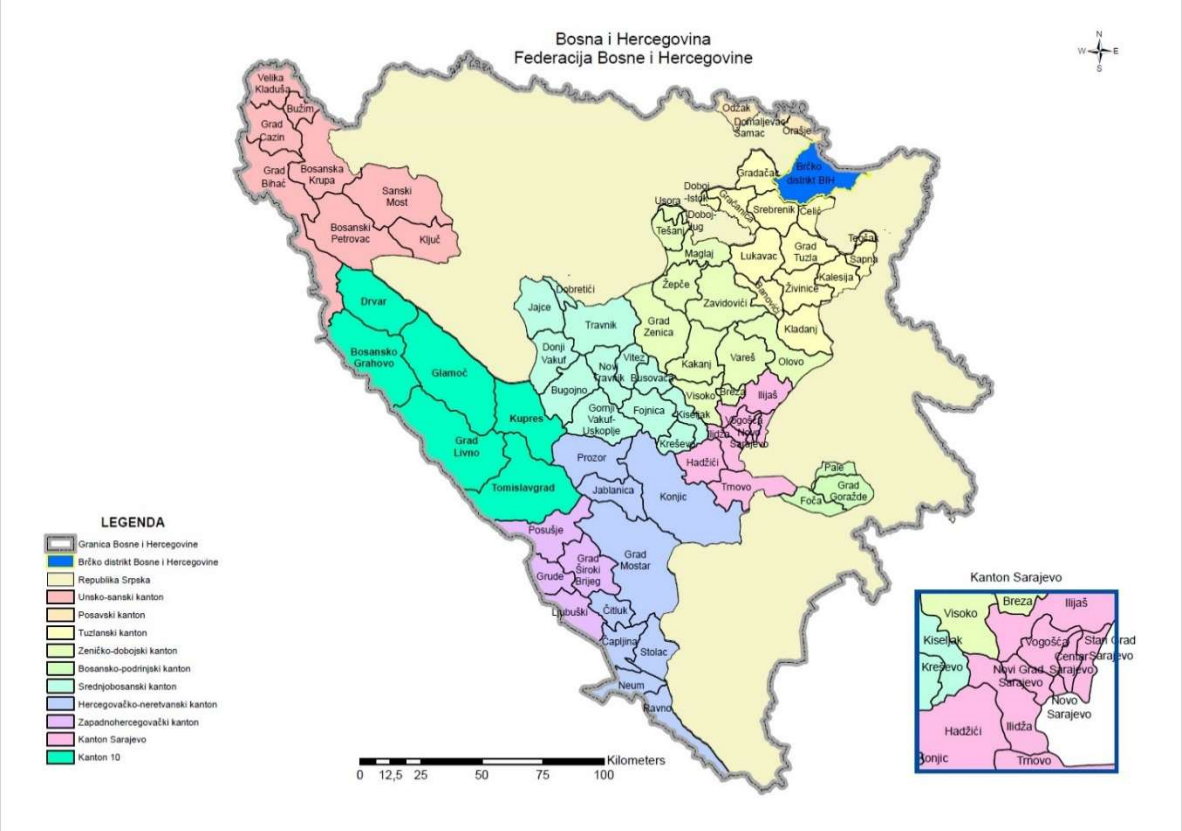

Slika 3.2 Teritorijalna karta Bosne i Hercegovine

Prema okvirnoj energetskoj strategiji Bosne i Hercegovine do 2035. godine, a sukladno jednom od zahtijeva direktive 2012/27/EU koji se odnosi na smanjenje i postizanje ušteda u finalnoj potrošnji energije, u BiH u sektoru zgradarstva definirane su sljedeće mjere [75]:

- obnova zgrada centralne uprave i javnih zgrada,
- implementacija dugoročne strategije obnove stambenog sektora,

- obnova javnih zgrada, uz pomoć donatora i projekata tehničke pomoći i
- uvođenje energetskog menadžmenta u javne zgrade.

Bosna i Hercegovina ima veliki potencijal za ostvarenje uštede energije, naročito u sektoru zgradarstva. U tom cilju prethodno je potrebno napraviti analizu postojećeg stanja stambenih i nestambenih zgrada, procjenu potrebnih investicija u energetsku učinkovitost te izraditi dugoročnu strategiju za obnovu zgrada uz implementaciju Direktive 2010/31/EU [75].

Direktiva 2010/31/EU o energetskoj učinkovitosti zgrada nalaže, s obzirom da zgrade imaju učinak na dugoročnu potrošnju energije, kao i na dugačak ciklus obnove postojećih zgrada, nove zgrade i postojeće zgrade koje se podvrgavaju značajnoj obnovi trebale ispuniti minimalne zahtjeve energetske učinkovitosti prilagođene lokalnoj klimi [76]. Čak i u zemljama koje su provele EPBD direktivu prije mnogo godina, još uvijek se postavljaju mnoga pitanja u vezi s njezinim utjecajem, opsegom i provedbom [18].

U proteklim godinama razvojni program Ujedinjenih nacija (*United Nations Development Programme, UNDP*) je ostvario značajan napredak u promociji energetske učinkovitosti u Bosni i Hercegovini. U središtu pažnje bilo je uvođenje energetske učinkovitosti u javnom sektoru, provođenjem pilot projekata energetske učinkovitosti i uvođenjem informacijskog sustava upravljanja energijom (*Energy Management Information System, EMIS*). Cilj ovih aktivnosti bilo je smanjenje potrošnje energije a time i smanjenje emisija stakleničkih plinova, očuvanje ograničenih resursa, uštede proračunskih sredstava, poboljšanje kvaliteta života, povećanje mogućnosti zapošljavanja i povećanje svijesti o koristima energetske učinkovitosti [77].

U Bosni i Hercegovini zakonski okvir za energetsku učinkovitost je u nadležnosti entiteta, i to Federacija Bosne i Hercegovine (FBiH) i Republika Srpska, te Brčko distrikta. Prethodna direktiva 2002/91/EC o energetskim karakteristikama zgrada u FBiH od 2009. godine bila je implementirana kroz Pravilnik o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije ("Sl. novine FBiH", br. 49/09) [78] i Pravilnik o energetskom certificiranju zgrada ("Sl. novine FBiH", br. 50/10) [79].

2017. godine stupio je na snagu Zakon o energetskoj učinkovitosti u FBiH ("Službene novine Federacije BiH", broj 22/17) [80] na temelju kojeg je donesen Pravilnik o minimalnim zahtjevima za energetskim karakteristikama zgrada ("Sl. novine FBiH", br. 81/19) [81] i „Uredba o provođenju energetskih audita i izdavanju energetskog certifikata ("Sl. novine FBiH", br. 87/18)“ [82].

Na temelju Zakona o energetskoj učinkovitosti u FBiH, u 2019. godini, donesen je Pravilnik o informacijskom sustavu energetske učinkovitosti FBiH koji uspostavlja, vodi i održava Fond za zaštitu okoliša FBiH. Ovim Pravilnikom utvrđena je struktura, forma, sadržaj i karakteristike sveobuhvatnog

Informacijskog sustava energetske učinkovitosti Federacije Bosne i Hercegovine (u daljnjem tekstu: ISEE), kao i način unosa i dostavljanja potrebnih podataka, te način izvještavanja. ISEE se bazira na web aplikacijama i bazama podataka preko kojih se unosi, analiza i prati potrošnja energenata u zgradama javnog sektora. ISEE baza podataka sadrži tehničke podatke svake zgrade, uključujući opće, građevinske i energetske podatke o zgradama, te dinamičke podatke o korištenju energenata koji sadrže sve podatke koji se nalaze na računima za potrošnju energije i vode, a koji se dostavljaju mjesečno [83].

Prije nego što se može izvršiti bilo koja vrsta obnove ili sanacije zgrade, potrebno je opsežno istražiti energetske karakteristike zgrade u trenutnom stanju i odgovarajuće predviđanje energetskog ponašanja naknadno primjenom predviđenih mjera poboljšanja. Jedna od tema koju je predložila Europska komisija u svojoj istraživačkoj i inovacijskoj politici (*Horizon 2020*) su novi alati i metodologije za smanjenje jaza između predviđenih i stvarnih energetskih karakteristika zgrada [84].

Ovo istraživanje je provedeno za školske zgrade osnovne i srednje škole u FBiH uključujući i školske sportske dvorane, ukoliko iste postoje uz školske zgrade. Dvorane sa stajališta funkcije i zajedničkih tehničkih sustava (grijanja, ventilacije, klimatizacije, elektroinstalacija) čine jednu cjelinu, a time i zajedničku potrošnju energije. Cilj je utvrditi energetske karakteristike postojećeg fonda školskih zgrada u FBiH kako bi se u idućim fazama istraživanja mogle utvrditi mjere za poboljšanje energetske učinkovitosti i smanjiti potrošnju i troškove za toplinsku energiju.

Cilj ovog istraživanja je izrada novih matematičkih modela koji će se moći koristiti za brže i jednostavnije predviđanje troškova toplinske energije školskih zgrada u FBiH i koji će se moći koristiti u inženjerskoj praksi između ostalog za potrebe vlasnika zgrada u svrhu upravljanja istim, donošenja odluka, planova i mjera za poboljšanje energetskih karakteristika i smanjenja potrošnje i troškova energije.

3.2 Podatci o karakteristikama javnih zgrada namijenjenih za obrazovanje u Federaciji Bosne i Hercegovine

U prvom koraku izvršeno je istraživanje osnovnih karakteristika i broja školskih zgrada u FBiH. U 2016. godini u Bosni i Hercegovini izrađena je tipologija stambenih zgrada [72], dok je izrada tipologije javnih zgrada u Bosni i Hercegovini (u daljnjem tekstu TJZ BiH) završena u 2018. godini. Tipologija javnih zgrada je dokument izrađen u okviru projekta ''Zeleni ekonomski razvoj'' koji implementira razvojni program Ujedinjenih nacija (*UNDP*) u Bosni i Hercegovini i predstavlja klasifikaciju i sistematizaciju svih javnih zgrada u BiH.

Prilikom izrade tipologije nestambenih zgrada javili su se problemi kao što su kompleksnost fonda nestambenih zgrada koja se ogleda u velikom broju različitih namjena, vrsta korisnika, građevinskih i ostalih karakteristika pojedinih zgrada, zatim nepostojanje nacionalnih registara javnih i drugih nestambenih zgrada koji bi sadržavali sve podatke neophodne za izradu tipologija, dok su istovremeno podatci iz službenih statistika prilično siromašni [77].

Javne zgrade različitih namjena imaju i različite godišnje potrebe za toplinskom energijom između ostalog zbog različitog režima rada i uporabe. Klasifikacija javnih zgrada prema namjeni prvenstveno je određena zakonskom regulativom, i to [77]:

- Direktivom EU 2010/31/EU o energetskim karakteristikama zgrada kojom je potrebno kategorizirati namjenu u svrhu proračuna energetskih karakteristika zgrade.
- Standardom BAS EN ISO 13790 kojim se vrši proračun potrebne energije za grijanje i hlađenje prostora i kojim se propisuju vrijednosti različitih proračunskih parametara za zgrade prema različitim kategorijama namjene. U odnosu na namjenu zgrade ovim standardom su definirane i unutarnje proračunske temperature, dnevni broj sati rada sustava za grijanje i drugi parametri potrebni za proračun potrebne energije.

Definirano je 7 sektora/tipova zgrada prema namjeni u TJZ BiH [77]:

1. Zgrade za predškolski odgoj što uključuje dječje vrtiće.
2. Zgrade u sektoru obrazovanja što uključuje osnovne i srednje škole, fakultete i druge obrazovne institucije. Zbog svojih specifičnih arhitektonskih karakteristika i temperaturnih zahtjeva, školske dvorane u okviru obrazovnih institucija svrstane su u zgrade za sportske djelatnosti.
3. Zgrade u zdravstvenom sektoru što uključuje domove zdravlja, ambulante, apoteke i druge slične ustanove koje pružaju dnevne usluge pacijentima. Bolnice i ostale ustanove za stacionarno liječenje pacijenata odnosno za njihov cjelodnevni boravak su isključene iz ove kategorije i uvrštene u kategoriju zgrada za cjelodnevni boravak.
4. Zgrade za sportske djelatnosti što uključuje gradske sportske dvorane jednostavnijih arhitektonskih oblika, školske dvorane i slično.
5. Zgrade za kulturne djelatnosti što uključuje domove kulture, kazališta, kina, biblioteke, itd.
6. Zgrade za administrativne djelatnosti što uključuje zgrade s uredskim prostorom iz raznih sektora (javna uprava, pravosuđe, sudstvo i policija, i slično).
7. Zgrade za cjelodnevni boravak što uključuje bolnice i ostale zgrade namijenjene stacionarnom liječenju pacijenata odnosno njihovom cjelodnevnom boravku, zatim studentske domove, ustanove za stalni boravak djece bez roditeljskog staranja, i slično.

Ovo istraživanje zajednički obuhvaća zgrade u sektoru obrazovanja koje uključuju zgrade za osnovne i srednje škole u FBiH i školske sportske dvorane koje sa školskim zgradama čine jednu cjelinu sa stajališta funkcije i zajedničkih tehničkih sustava (grijanja, ventilacije, klimatizacije, elektroinstalacija), a time i zajedničke potrošnju energije.

Druga klasifikacija javnih zgrada je izvršena u odnosu na razdoblje izgradnje. Različita razdoblja izgradnje imaju različite karakteristike građevinskih dijelova ovojnice, različite tehnologije građenja i pojavu novih građevinskih materijala. Također tijekom vremena mijenjala se zakonska regulativa vezana za toplinsku zaštitu kojom su se pooštravali zahtjevi. Definirana razdoblja izgradnje u TJZ BiH prikazani su tablici 3.1.

Tablica 3.1 Razdoblja izgradnje javnih zgrada u BiH [77]

Ozn.	Razdoblja izgradnje	Osnovne karakteristike zgrada
A	do 1945. godine	Zgrade građene tradicionalnim tehnikama bez primjene toplinske zaštite. Primijenjeni materijali su uglavnom imali zadatak zadovoljiti potrebe nosivosti dok se toplinska zaštita zgrada nije primjenjivala. Karakteriziraju ih veliki gubitci toplinske energije, jer se vanjski masivni zidovi uglavnom izgrađeni od opeke ili kamena. Međukatne konstrukcije su pretežno drvene, ili masivne od opeke ili kamena, te ponekad (u kasnijem dijelu ovog razdoblja) od rebrastog betona. Podrumske prostorije u ovim zgradama su uglavnom negrijani prostori s masivnim zidovima, čija je svrha na neki način bila odvajanje prostore za boravak od tla. Stropovi prema negrijanom prostoru (tavanu) su najčešće drveni s obostranom daščanom oplatom i međuprostorom koji je popunjen šutom. Kao što je podrum bio tampon između prostora za boravak i tla, tako je i tavan bio tampon prema vanjskom zraku. Prozori i vrata su bili drveni s jednim staklom, ili dvostruki s dva krila na razmaku od oko 10 cm.
B	od 1946. do 1965. godine	U ovom razdoblju počinje razvoj i primjena novih materijala. Primjena armiranog betona i gradnja vrlo tankih armirano-betonskih elemenata (zidova i ploča), te razvoj industrijske gradnje koju karakteriziraju montažni elementi, velikoplošne oplate, i nove tehnologije građenja omogućavaju gradnju visokih zgrada i smanjuju rokove izgradnje. Projekti zgrada su rađeni isključivo s ciljem zadovoljavanja statičkih kriterija i potreba za što kraćim rokovima izgradnje. Istovremeno je u potpunosti zanemarena toplinska zaštita zgrada, što je zbog primjene tanjih zidova i ostalih građevinskih elemenata prouzrokovalo znatno lošiju toplinsku izolaciju zgrada izgrađenih u tom razdoblju, nego kod zgrada rađenih u prethodnom razdoblju. Posljedica ovakve gradnje bila je pojačana potrošnja toplinske energije, te pojava vlage ili kondenzacije uslijed neizoliranih toplinskih mostova. To je dovodilo do razaranja građevinske strukture pojedinih građevinskih dijelova kao i do pojave gljivica i plijesni u prostorijama za boravak što je imalo negativan utjecaj na zdravlje. Zbog ovoga se ukazala potreba za zakonodavnim reguliranjem gradnje s ciljem ublažavanja navedenih negativnih posljedica.

C i D	od 1966. do 1973. godine od 1974. do 1987. godine	Ova dva razdoblja su značajna zbog toga što se zakonodavnim mjerama počinje utjecati na poboljšanje toplinske zaštite zgrada (Pravilnik o tehničkim mjerama i uvjetima za toplinsku zaštitu zgrada – 1970 god.) što između ostalog uključuje obvezu izolacije toplinskih mostova tankim izolacijskim slojevima debljine 2-4 cm, a nakon toga definiranje minimalnih vrijednosti koeficijenta prolaska topline 'k' (danas 'U') za pojedine dijelova vanjske ovojnice (norma JUS U.J5.600 izdanje 1980 god. i inovirano izdanje norme JUS.U.J5.600 1987 god.). Ovi propisi svakako pozitivno utječu na smanjenje potrebne toplinske energije i na smanjenje negativnih utjecaja toplinskih mostova. U ovom razdoblju se pojavljuju novi izolacijski materijali, pa zgrade iz ovog razdoblja karakterizira pojava termoizolacijskog dvostrukog stakla, međutim okviri prozora su još uvijek bez neprekinutog toplinskog mosta. Još uvijek se ne sagledavaju energetske potrebe zgrade kao cjeline, i energetski proračun se ne vrši za zgradu kao cjelinu. Zgrade iz ovog razdoblja karakteriziraju vrlo razuđene arhitektonske forme s vrlo lošim faktorom oblika, te velike staklene površine na vanjskim zidovima.
E	od 1988. do 2009. godine	Ovo razdoblje je karakteristično po vrlo slabom intenzitetu gradnje u razdoblju neposredno prije, za vrijeme i poslije rata 1991-1995, te po značajnijoj primjeni novih materijala u razdoblju poslije 2000. godine. Naime, tek nakon 2000. godine javlja se značajnija primjena termoizolacijskih materijala kao što su polistiren i mineralna vuna (debljina 5-10 cm) te prozora s termoizolacijskim staklima i prekinutim toplinskim mostovima. To se međutim još uvijek događa spontano, bez zakonske obaveze, samo na osnovu spoznaja investitora i projektanata i njihove vlastite potrebe smanjenja troškova grijanja.
F	poslije 2010. godine	U ovom razdoblju pokrenuto je reguliranje oblasti toplinske zaštite zgrada, i prvi put se zgrade počinju promatrati i proračunavati kao jedinstvene energetske cjeline. U Federaciji BiH je 2009. godine stupio na snagu *Pravilnik o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije*. U ovom razdoblju je također prisutan značajan utjecaj programa i projekata međunarodnih organizacija iz oblasti energetske učinkovitosti, na širenje znanja i svijesti o potrebi i dobrobitima toplinske zaštite zgrada. U ovom razdoblju se intenzivira izgradnja i rekonstrukcija zgrada s toplinskim karakteristikama znatno boljim nego kod zgrada iz prethodnih razdoblja izgradnje.

Podatci iz tablice 3.1 prikazuju osnovne karakteristike zgrada sa stajališta načina izgradnje i primijenjenih materijala u kontekstu toplinske zaštite prema razdobljima izgradnje.

Dokument tipologije javnih zgrada u BiH u konačnici je rezultirao matricom tipološke klasifikacije s ukupno 42 tipa, tj. s 6 razdoblja izgradnje i 7 sektora namjene. U tablici 3.2 prikazana je raspodjela ukupnog broja javnih zgrada u BiH po tipovima (razdoblje izgradnje i namjena).

Tablica 3.2 Ukupan broj javnih zgrada u BiH po tipovima [77]

		I	II	III	IV	V	VI	VII		
		PREDŠKOLSKI ODGOJ	OBRAZOVANJE	ZDRAVSTVO	SPORT	KULTURA	ADMINISTRATIVNE	CJELODNEVNI BORAVAK	UKUPNO	UDIO (%)
A	do 1945		215	33		65	223		536	7,1%
B	od 1946 do 1965	15	822	145	141	97	611	74	1.905	25,1%
C	od 1966 do 1973	35	444	98	166	56	341	75	1.215	16,0%
D	od 1974 do 1987	80	526	289	304	113	831	90	2.233	29,4%
E	od 1988 do 2009	28	359	200	103	48	554	88	1.380	18,2%
F	poslije 2010	12	68		56		195		331	4,4%
UKUPNO		170	2.434	765	770	379	2.755	327	7.600	100,0%
UDIO (%)		2,2%	32,0%	10,1%	10,1%	5,0%	36,3%	4,3%	100,0%	

Iz tablice se 3.2 može primijetiti kako najveći udio u ukupnom broju javnih zgrada u BiH imaju administrativne zgrade s udjelom od 36,3% a zatim slijede obrazovne zgrade s udjelom od 32,0%. Budući je BiH teritorijalno i administrativno podijeljena u cjeline koji imaju svoje posebne zakone i propise koji između ostalog zasebno reguliraju područje toplinske zaštite u tablici 3.3 prikazana je podjela ukupnog broja javnih zgrada u BiH po administrativnim cjelinama.

Tablica 3.3 Ukupan broj javnih zgrada u BiH po administrativnim cjelinama [77]

Administrativna cjelina	Ukupno	Udio
Federacija BiH	4.419	58,1%
Republika Srpska	2.908	38,3%
Distrikt Brčko	216	2,8%
Nadležnost BiH	57	0,8%
Sveukupno	7.600	100,0%

Iz tablice 3.3 može se vidjeti kako najveći udio u ukupnom broju javnih zgrada u BiH čine zgrade teritorijalno smještene u FBiH u iznosu od 58,1 % te će se ovo istraživanje usmjeriti na javne zgrade u FBiH. U idućoj tablici 3.4 prikazana je raspodjela ukupnog broja javnih zgrada u Federaciji Bosne i Hercegovine (FBiH) po broju u odnosu na razdoblje izgradnje i namjenu.

Tablica 3.4 Ukupan broj javnih zgrada u FBiH po tipovima [77]

		I	II	III	IV	V	VI	VII		
		PREDŠKOLSKI ODGOJ	OBRAZOVANJE	ZDRAVSTVO	SPORT	KULTURA	ADMINISTRATIVNE	CJELODNEVNI BORAVAK	UKUPNO	UDIO (%)
A	do 1945		109	17		35	120		281	6,4%
B	od 1946 do 1965	10	498	102	101	44	355	31	1.141	25,8%
C	od 1966 do 1973	25	250	46	101	16	174	38	650	14,7%
D	od 1974 do 1987	45	343	183	206	40	524	51	1.392	31,5%
E	od 1988 do 2009	19	212	126	49	19	321	52	798	18,1%
F	poslije 2010	4	43		28		82		157	3,6%
UKUPNO		103	1.455	474	485	154	1.576	172	4.419	100,0%
UDIO (%)		2,3%	32,9%	10,7%	11,0%	3,5%	35,7%	3,9%	100,0%	

Iz tablice 3.4 može se vidjeti kako prema broju zgrada u odnosu na namjenu najveći broj zgrada se odnosi na zgrade namijenjene za administrativne djelatnosti (zgrade s uredskim prostorom iz raznih sektora) s udjelom od 35,7%, zatim slijede zgrade namijenjene za obrazovanje (osnovne i srednje škole, fakulteti i druge obrazovne institucije) s udjelom od 32,9%. Međutim, osim broja zgrada namijenjenih određenoj namjeni bitna je i korisna površina (A_k) kao i režim rada što utječe na troškove uporabe istih. U idućoj tablici 3.5 prikazana je raspodjela javnih zgrada u Federaciji Bosne i Hercegovine prema korisnoj površini (A_k).

Tablica 3.5 Raspodjela korisne površine (A_k) javnih zgrada u FBiH po tipovima [77]

		I	II	III	IV	V	VI	VII		
		PREDŠKOLSKI ODGOJ	OBRAZOVANJE	ZDRAVSTVO	SPORT	KULTURA	ADMINISTRATIVNE	CJELODNEVNI BORAVAK	UKUPNO	UDIO (%)
A	do 1945		105.089	14.952		33.153	134.418		287.612	5,6%
B	od 1946 do 1965	4.092	466.471	86.385	42.149	73.533	338.320	120.886	1.131.836	21,9%
C	od 1966 do 1973	17.625	355.042	52.192	35.318	14.003	131.596	77.888	683.664	13,2%
D	od 1974 do 1987	39.971	570.257	341.986	109.006	116.733	446.832	363.098	1.987.883	38,5%
E	od 1988 do 2009	10.147	198.070	86.152	52.798	33.216	304.004	221.315	905.702	17,5%
F	poslije 2010	1.961	31.913		58.488		72.228		164.590	3,2%
UKUPNO		73.796	1.726.842	581.667	297.759	270.638	1.427.398	783.187	5.161.287	100,0%
UDIO (%)		1,4%	33,5%	11,3%	5,8%	5,2%	27,7%	15,2%	100,0%	

Iz tablice 3.5 može se vidjeti kako u odnosu na korisnu površinu (A_k) najveća korisna površina se odnosi na zgrade namijenjene za obrazovanje s udjelom od 33,5% a zatim slijede zgrade za administrativne djelatnosti s udjelom od 27,7%.

S obzirom da je udio površine zgrada namijenjenih za u ukupnoj površini javnih zgrada FBiH veći od 33% (1/3 površine svih javnih zgrada u FBIH otpada na zgrade namijenjene za obrazovanje) naglašava se važnost ovog istraživanja.

Kako školske zgrade imaju veliko društveno značenje, u razdoblju od 2010 do 2018. godine, najveći broj pokrenutih aktivnosti (izrada detaljnih energetskih pregleda) i provođenja mjera energetske učinkovitosti (toplinsko izoliranje ovojnice zgrade) u javnom sektoru u FBiH provedeno je nad zgradama namijenjenim za obrazovanje u FBiH.

U tipologiji javnih zgrada BiH definirano je nekoliko značajnih varijabli koje na najbolji način definiraju osobine pojedinih zgrada i tipova [77]:

- korisna površina zgrade (A_k) koja predstavlja ukupnu neto podnu površinu grijanog dijela zgrade,
- površina ovojnice grijanog dijela zgrade (A) koja predstavlja ukupnu površinu građevinskih dijelova ovojnice zgrade koji razdvajaju grijani dio zgrade od vanjskog prostora, tla ili negrijanih prostora,
- volumen grijanog zraka (V_e) predstavlja bruto volumen grijanog dijela zgrade kojem je površina ovojnice A,
- faktor oblika zgrade koji predstavlja odnos površine vanjske ovojnice grijanog dijela zgrade (A) i volumena grijanog dijela zgrade (V_e) i definira kompaktnost zgrade i
- prosječan koeficijent prolaska topline ovojnice zgrade (U).

U tablicama 3.6 i 3.7 prikazani su ukupni i prosječni podatci za značajne varijable i potrebnu toplinsku energiju za grijanje zgrada namijenjenih za obrazovanje u FBiH (u daljnjem tekstu zgrada za obrazovanje u FBiH).

Tablica 3.6 Raspodjela korisne površine (A_k), volumena grijanog zraka (V_e), površine ovojnice grijanog dijela (A) zgrada za obrazovanje u FBiH [77]

ZGRADE ZA OBRAZOVANJE U FBIH		Ukupna korisna površina A_k (m^2)	Prosječna korisna površina A_k (m^2)	Ukupni volumen grijanog zraka V_e (m^3)	Prosječni volumen grijanog zraka V_e (m^3)	Ukupna površina ovojnice grijanog dijela A (m^2)	Prosječna površina ovojnice grijanog dijela A (m^2)
A	do 1945	105.089	964	385.859	3.540	206.946	1.899
B	od 1946 do 1965	466.471	937	1.560.807	3.134	931.315	1.870
C	od 1966 do 1973	355.042	1.420	1.170.426	4.682	641.719	2.567
D	od 1974 do 1987	570.257	1.663	1.894.758	5.524	970.689	2.830
E	od 1988 do 2009	198.070	934	631.129	2.977	365.279	1.723
F	poslije 2010	31.913	742	104.322	2.426	63.899	1.486
	UKUPNO	1.726.842	1.187	5.747.301	3.950	3.179.847	2.185

Tablica 3.7 Raspodjela vrijednosti faktora oblika (f_o), koeficijenta prolaska topline (U), ukupne potrebne toplinske energije za grijanje $Q_{H,nd}$ i specifične potrebne toplinske energije za grijanje $Q'_{H,nd}$ zgrada za obrazovanje u FBiH [77]

ZGRADE ZA OBRAZOVANJE U FBIH		Prosječna vrijednost faktora oblika $f_0=A/V_e$ (m^{-1})	Prosječni koeficijent prolaska topline vanjske ovojnice U (W/m^2K)	Ukupna godišnja potrebna toplinska energija za grijanje $Q_{h,nd}$ (MWh/god)	Specifična godišnja potrebna toplinska energija za grijanje $Q'_{h,nd}$ (kWh/m^2god)
A	do 1945	0,54	1,66	16.736	159,3
B	od 1946 do 1965	0,60	1,81	85.268	182,8
C	od 1966 do 1973	0,55	1,78	64.096	180,5
D	od 1974 do 1987	0,51	1,78	102.639	180,0
E	od 1988 do 2009	0,58	1,66	26.571	134,1
F	poslije 2010	0,61	1,66	2.955	92,6
	UKUPNO	0,55	1,70	298.266	172,7

U dokumentu TJZ BiH izvršen je izbor karakterističnih zgrada koje na najbolji način predstavljaju određen tip definiran matricom. Njihov izbor za svaki tip izvršen je na uzorku formiranom od svih zgrada koje pripadaju razmatranom tipu. Pri izboru karakteristične zgrade za svaki tip, odnosno za identifikaciju položajno najreprezentativnije zgrade primijenjen je princip pronalaženja zgrade koja na osnovi medijane ima približno isti faktor oblika, uz istovremeno uspoređivanje vrijednosti ostalih značajnih varijabli (prosječan koeficijent prolaska topline vanjske ovojnice, korisne površine grijanog dijela i volumena grijanog zraka) [77]. U tablici 3.8 je dan prikaz karakteristika zgrada za obrazovanje u FBiH.

Tablica 3.8 Karakteristike zgrada za obrazovanje u FBiH prema razdoblju izgradnje [77]

ZGRADE ZA OBRAZOVANJE U FBIH		Ukupna površina pojedinih dijelova ovojnice u FBiH (m^2)	Prosječna površina pojedinih dijelova ovojnice u FBiH (m^2)	Prosječni koeficijent prolaska topline ''U'' u FBiH (W/m^2K)	Opis dijelova vanjske ovojnice zgrada
do 1945	zid	80.764	741	1,52	Masivni vanjski zidovi izrađeni su uglavnom od pune opeke debljine 48 cm, obostrano ožbukani, izvedeni uglavnom bez sloja termoizolacije.
	otvor	16.626	153	3,06	Vanjski otvori su uglavnom izrađeni od drvenih okvira, dvostruki, sa spojenim krilima i jednostrukim staklom, a manjim dijelom s okvirom od PVC.
	pod	54.464	500	1,70	Različiti završni slojevi poda izvedeni na cementnom estrihu. Hidroizolacija izvedena na betonskoj podnoj ploči debljine 10 cm i sloja šljunka.
	zadnji strop/krov	55.092	505	1,40	Zadnji strop prema tavanu uglavnom je izrađen od drvenih greda s plafonom izvedenim od žbuke na sloju trske, a manjim dijelom od armiranog betona.
	ovojnica	206.946	1.899	1,66	Slobodnostojeća zgrada pravokutne osnove s četvorovodnim krovom. Ovojnica bez termoizolacije. Najveći toplinski gubitci kroz vanjske zidove.
od 1946 do 1965	zid	315.836	634	1,57	Masivni vanjski zidovi izrađeni su uglavnom od pune opeke debljine 40 cm, obostrano ožbukani, izvedeni uglavnom bez sloja termoizolacije.
	otvor	98.382	198	3,12	Vanjski otvori na zgradi su izrađeni uglavnom od drvenih okvira, dvostruki, sa spojenim krilima i jednostrukim staklom, i manjim dijelom od okvira od PVC i Alu.
	pod	256.903	516	1,69	Različiti završni slojevi poda izvedeni na cementnom estrihu. Hidroizolacija izvedena na betonskoj podnoj ploči debljine 10 cm i sloja šljunka.
	zadnji strop/krov	260.194	522	1,72	Zadnji strop prema tavanu izrađen je od armiranog betona ili drvenih greda s plafonom izvedenim od žbuke na sloju trske.
	ovojnica	931.315	1.870	1,81	Slobodnostojeća zgrada pravokutne osnove s četvorovodnim krovom. Ovojnica bez termoizolacije. Najveći toplinski gubitci kroz vanjske zidove i zadnji strop.
od 1966 do 1973	zid	186.118	744	1,50	Masivni vanjski zidovi izrađeni su uglavnom od pune opeke, debljine 36 cm, a manjim dijelom od blok opeke, plinobetona i armiranog betona, obostrano ožbukani, od ukupne površine vanjskog zida na 11% površine je postavljen sloj termoizolacije, prosječne debljine 8 cm.
	otvor	79.142	317	2,74	Vanjski otvori su izrađeni uglavnom od drvenih okvira, dvostruki, sa spojenim krilima i jednostrukim staklom i manjim dijelom od okvira od Alu i PVC.
	pod	187.610	750	1,56	Najčešći završni sloj poda su vinaz trake izvedeni na cementnom estrihu. Hidroizolacija izvedena na betonskoj podnoj ploči debljine 10 cm i sloja šljunka.
	zadnji strop/krov	188.849	755	1,87	Zadnji strop prema tavanu izrađen je uglavnom od armiranog betona i ožbukan, a dijelom od drvenih greda i monta gredica, izvedeni uglavnom bez sloja termoizolacije.
	ovojnica	641.719	2.567	1,78	Slobodnostojeća zgrada je pravokutne osnove sa složenim krovom. Ovojnica uglavnom bez termoizolacije. Najveći toplinski gubitci kroz vanjske zidove i zadnji strop.
od 1974 do 1987	zid	262.185	764	1,41	Vanjski zidovi izrađeni su uglavnom od blok opeke, debljine 29 cm a manjim dijelom od pune opeke, plinobetona i armiranog betona, obostrano ožbukani, od ukupne površine vanjskog zida na 13% površine je postavljen sloj termoizolacije, prosječne debljine 8 cm.
	otvor	115.403	336	2,64	Vanjski otvori su izrađeni uglavnom od drvenih okvira, dvostruki, sa spojenim krilima i jednostrukim ili dvostrukim staklom i manjim dijelom od okvira od PVC i Alu.
	pod	295.554	862	1,53	Najčešći završni sloj poda su vinaz trake izvedeni na cementnom estrihu. Hidroizolacija izvedena na betonskoj podnoj ploči debljine 10 cm i sloja šljunka.

	zadnji strop/krov	297.548	867	2,01	Zadnji strop prema tavanu izrađen je uglavnom od armiranog betona i ožbukan, a dijelom od drvenih greda i monta gredica, izvedeni uglavnom bez sloja termoizolacije.
	ovojnica	970.690	2.830	1,78	Zgrada je razvedenog tlocrta sa složenim krovom. Ovojnica uglavnom bez termoizolacije. Najveći toplinski gubitci kroz zadnji strop.
od 1988 do 2009	zid	114.195	539	1,23	Vanjski zidovi izrađeni su uglavnom od blok opeke, debljine 25 cm a manjim dijelom od pune opeke, plinobetona i armiranog betona, obostrano ožbukani, od ukupne površine vanjskog zida na 36% površine je postavljen sloj termoizolacije, prosječne debljine 7 cm.
	otvor	32.803	155	2,20	Vanjski otvori su izrađeni uglavnom od drvenih okvira, s dvostrukim termo staklom i manjim dijelom od okvira od PVC i Alu.
	pod	109.154	515	0,92	Najčešći završni sloj poda je parket izveden na cementnom estrihu ispod koje se nalazi sloj termoizolacije. Hidroizolacija izvedena na betonskoj podnoj ploči debljine 10 cm i sloja šljunka.
	zadnji strop/krov	109.127	515	1,14	Zadnji strop prema tavanu izrađen je uglavnom od armiranog betona i ožbukan, a dijelom od monta gredica, izvedeni uglavnom bez sloja termoizolacije.
	ovojnica	365.279	1.723	1,20	Zgrada je razvedenog tlocrta sa složenim krovom. Ovojnica je samo djelomično toplinski izolirana. Najveći toplinski gubitci kroz vanjske zidove i zadnji strop.
poslije 2010	zid	20.902	486	0,89	Vanjski zidovi izrađeni su uglavnom od blok opeke, debljine 25 cm a manjim dijelom od pune opeke, plinobetona i armiranog betona, obostrano ožbukani, od ukupne površine vanjskog zida na 57% površine je postavljen sloj termoizolacije, prosječne debljine 8 cm.
	otvor	5.462	127	1,54	Vanjski otvori su izrađeni uglavnom od PVC okvira, minimalno petokomorni, s dvostrukim termostaklom i manjim dijelom od okvira od drveta i Alu.
	pod	18.765	436	0,92	Najčešći završni sloj poda je parket izveden na cementnom estrihu ispod koje se nalazi sloj termoizolacije. Hidroizolacija izvedena na betonskoj podnoj ploči debljine 10 cm i sloja šljunka.
	zadnji strop/krov	18.769	436	1,04	Zadnji strop prema tavanu izrađen je uglavnom od armiranog betona i ožbukan, a dijelom od monta gredica, izvedeni dijelom sa slojem termoizolacije.
	ovojnica	63.898	1.486	1,00	Zgrada je razvedenog tlocrta s ravnim krovom. Ovojnica je u jednom dijelu (ne potpuno) termoizolirana. Najveći toplinski gubitci kroz vanjske zidove i zadnji strop.
Sveukupno	zid	980.000	674	1,46	Vanjski zidovi izrađeni od pune opeke ili blok opeke, a manjim dijelom od plinobetona i armiranog betona, obostrano ožbukani, na dijelu površine zidova je postavljen sloj termoizolacije.
	otvor	347.818	239	2,76	Vanjski otvori su izrađeni uglavnom od drvenih okvira, s jednostrukim ili dvostrukim staklom i manjim dijelom od okvira od PVC i Alu.
	pod	922.450	634	1,51	Najčešći završni sloj poda su vinaz trake izvedeni na cementnom estrihu najčešće bez sloja termoizolacije. Hidroizolacija izvedena na betonskoj podnoj ploči debljine 10 cm i sloja šljunka.
	zadnji strop	929.579	639	1,74	Zadnji strop prema tavanu izrađen je uglavnom od armiranog betona i ožbukan, a dijelom od drvenih greda i monta gredica, izvedeni uglavnom bez sloja termoizolacije.
	ovojnica	3.179.847	2.185	1,70	Ovojnica je samo djelomično termoizolirana. Najveći toplinski gubitci kroz vanjske zidove i zadnji strop.

U dokumentu TJZ BiH također je izvršena podjela ukupnog broja obrazovnih zgrada u FBiH u klimatske regije ''sjever'' i ''jug'' koje se odnose na klimatološke karakteristike lokacija. Podjela se vrši u odnosu na srednju mjesečnu temperaturu najhladnijeg mjeseca u godini i ukoliko je ona manja od 3,0 °C onda lokacija pripada u regiju ''sjever'' (skraćenica RS FBiH), odnosno ako je srednja mjesečna temperatura najhladnijeg mjeseca veća od 3,0 °C onda lokacija pripada u regiju ''jug'' (skraćenica RJ FBiH). Dio zahtijeva definiranih Pravilnikom o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije ("Sl. novine FBiH", br. 49/09) također je određen u odnosu na srednju mjesečnu

temperaturu najhladnijeg mjeseca u godini. U tablici 3.9 prikazana je raspodjela ukupnog broja obrazovnih zgrada u FBiH i u odnosu klimatske regije ''sjever'' i ''jug''.

Tablica 3.9 Ukupan broj zgrada za obrazovanje u FBiH u odnosu na klimatske regije [77]

ZGRADE ZA OBRAZOVANJE U FBIH		BROJ ZGRADA U FBiH	UDIO (%)	BROJ ZGRADA U REGIJI SJEVER FBiH	UDIO (%)	BROJ ZGRADA U REGIJI JUG FBiH	UDIO (%)
A	do 1945	109	7,5%	89	7,5%	20	7,6%
B	od 1946 do 1965	498	34,2%	408	34,2%	90	34,2%
C	od 1966 do 1973	250	17,2%	205	17,2%	45	17,1%
D	od 1974 do 1987	343	23,6%	281	23,6%	62	23,6%
E	od 1988 do 2009	212	14,6%	174	14,6%	38	14,4%
F	poslije 2010	43	3,0%	35	2,9%	8	3,0%
	UKUPNO	1.455	100,0%	1.192	100,0%	263	100,0%

Iz prethodne tablice 3.9 je vidljivo da je najveći broj zgrada za obrazovanje u FBiH izgrađen u razdoblju od 1946. do 1965. godine (34,2%), a zatim slijedi razdoblje od 1974. do 1987. godine (23,6%). U razdoblju od 1946. do 1987. godine izgrađen je najveći broj škola, odnosno 1.091 škola (75%). U odnosu na klimatske regije najveći broj škola je smješten u klimatsku regiju ''sjever'', približno 81,9% (1.192/1.455).

3.3 Prikupljanje i obrada podataka o karakteristikama školskih zgrada u FBiH

Postavlja se pitanje na koji način doći do uzorka koji će biti osnova za prikupljanje podataka za ovo istraživanje? Istraživanja pokazuju kako postojeći skupovi podataka o potrošnji energije u zgradama općenito se mogu kategorizirati prema tri glavne strategije pomoću kojih se generiraju ili dobivaju uzorci podataka [85]:

- strategija mjerenja predstavlja mjerne stvarnih podataka o potrošnji energije. Ona je skupa i izazovna, posebno u situacijama koje zahtijevaju detaljno mjerenje, duga razdoblja prikupljanja podataka i široku pokrivenost više zgrada. Zbog navedenih poteškoća, mnogi istraživači radije koriste skupove podataka o potrošnji energije koje generiraju i dijele drugi istraživači, umjesto da prikupljaju vlastite skupove podataka.
- strategija istraživanja prikuplja uzorke podataka intervjuiranjem pojedinaca i/ili iz drugih baza podataka ili izvora, te je prikladna za kvantitativno i kvalitativno prikupljanje podataka.

Rezultirajući skupovi podataka korisni su za utvrđivanje profila i ponašanja potrošača u potrošnji energije, karakteristikama zgrade i drugih čimbenika kao što su kompatibilnost s okolišem i razina udobnosti potrošača. Iako podatci ankete sadrže manje detalja u odnosu na podatke mjerenja in-situ, ova se strategija može koristiti za zemljopisno raspoređene potrošače koji pokrivaju veliku populaciju.

- strategija simulacije ekonomski je način generiranja podataka o potrošnji energije. Simulacije se mogu izvoditi na brz, prikladan i isplativ način te se obično koriste softverski paketi koji omogućuju jednostavnu promjenu parametara modela kako bi se istražili obrasci potrošnje energije s obzirom na različite parametre.

Za ovo istraživanje koristiti će se ''strategija istraživanja'' prikupljanjem podataka iz određenih pouzdanih izvora ili baza kako bi uzorak bio reprezentativan i pouzdan. Kako je već u prezentirano u poglavlju 3.2 dokument Tipologija javnih zgrada u BiH sadrži opće prosječne podatke o geometrijskim i toplinskim karakteristikama zgrada za obrazovanje u FBiH, ali ne sadrži podatke o troškovima energije istih i predstavlja osnovnu bazu razmatranih zgrada. Stoga se pristupilo istraživanju traženja drugih izvora koji sadrže detaljnije podatke o potrošnji energije, troškovima potrošnje energenata, veličinama i građevinskim karakteristikama dijelova ovojnice, režimu uporabe kao i o drugim podatcima neophodnim za provođenje ovog istraživanja.

U 2019. godini donesen je Pravilnik o informacijskom sustavu energetske učinkovitosti FBiH kojim upravlja Fond za zaštitu okoliša FBiH te je razvijen informacijski sustav energetske učinkovitosti (*ISEE*) FBiH koji obvezuje sve nositelje na unos podataka i dostavljanje informacija Fondu. Nositelji unosa podataka su prema ovom pravilniku organi i tijela Federacije BiH, kantoni (županije), organi javne uprave, organizacije, regulatorna tijela, javne ustanove, agencije, javna poduzeća, veliki potrošači energije, operatori distributivnog sistema, distributeri energije i snabdjevači energijom.

Početkom 2019. godine za potrebe ovog istraživanja upućen je zahtjev prema Fondu za zaštitu okoliša FBiH kojim su se tražili podatci iz baze ISEE za zgrade namijenjene za obrazovanje u FBiH. Od Fonda su dobiveni podatci gdje su zgrade svrstane po administrativnim cjelinama (kantonima/županijama) u FBiH. Podatci su obuhvaćali sljedeće informacije:

- opći podatci (ID županije, ISEE šifra, naziv zgrade, grad) i
- podatci o zgradi i korištenim energentima (korisna površina zgrade, energenti koji se troše, godišnji troškovi energenata, potrošenoj energiji u kWh, godišnjoj emisiji CO_2, specifičnim troškovima i specifičnoj potrošnji energije).

Kako je baza ISEE sustava tek u razvoju vrlo mali dio nositelja podataka je obavio unos podataka. Također, sagledavajući i analizirajući dobivene podatke uočeno je kako isti nisu potpuni, dovoljni i potrebni za ovo istraživanje jer ne postoje podatci o površini ovojnice, volumenu grijanog prostora, faktoru oblika, površinama i karakteristikama građevinskih dijelova vanjske ovojnice kojim bi se mogla utvrditi povezanost karakteristika zgrade s troškovima toplinske energije istih.

Istraživanje koje se odnosilo na analizu podatka o karakteristikama javnih zgrada koje se unose u Informacijski sustav upravljanja energijom (*Energy Management Information System, EMIS*) u Republici Hrvatskoj pokazalo je kako nedostaje dio podataka ili su vrijednosti podataka izvan mogućeg raspona vrijednosti, a vjerojatna su posljedica pogreške unosa korisnika. U nekim slučajevima nedostaje ili su isključeni 80 % podataka [86]. Podatci o karakteristikama javnih zgrada koje se unose u Informacijski sustav upravljanja energijom (*EMIS*) mogu se koristiti za statističke analize kao i za složenije analize kojima se vrši izrada modela za predviđanje energetskih karakteristika zgrada [87].

Zbog nedostatka dovoljnih podataka za ovo istraživanje u ISEE bazi pristupilo se traženju drugog izvora podataka. U proteklom razdoblju (od 2010. godine) preko različitih institucija (Fond za zaštitu okoliša FBiH, županijski fondovi za zaštitu okoliša, federalna i županijska ministarstva prostornog uređenja i građenja, *UNDP*) pokrenute su akcije i projekti povećanja energetske učinkovitosti u sektoru javnih institucija gdje su navedene institucije dodjeljivale sredstva putem natječaja za aktivnosti na povećanju energetske učinkovitosti.

Jedan od temeljnih uvjeta za apliciranje na navedenim natječajima je analiza potrošnje energije i definiranje mjera za poboljšanje energetske učinkovitosti što se provodi putem izrade detaljnih energetskih pregleda zgrada. Detaljni energetski pregled ili audit (DEA) je dokumentirani postupak koji se provodi u cilju utvrđivanja energetskih karakteristika zgrada i stupnja ispunjenosti tih karakteristika u odnosu na zahtjeve propisane posebnim propisima i sadrži prijedlog mjera za ekonomski povoljno poboljšanje energetskih karakteristika zgrada [88]. Energetska provjera ili audit glavni je alat za razumijevanje potrošnje energije u zgradama i posljedično učinkovito interveniranje. Zapravo se radi o temeljitoj analizi provedenoj na samoj zgradi u svrhu ispitivanja potrošnje energije kako bi se dobio pregled trenutnog stanja potrošnje energije i utvrdile moguće intervencije (mjere) usmjerene na poboljšanje zgrade u pogledu vanjske ovojnice i zamjenu postojećih tehnologija kako bi se smanjila potrošnja goriva i električne energije [13].

Energetske preglede provode stručne ovlaštene osobe (koje su prošle program obuke i dobile ovlaštenja) prema propisanim smjernicama za izradu istih. Smjernice za provođenje energetskog pregleda zgrada daju zajedničku metodologiju provođenja, a osnovni je cilj utvrditi energetske karakteristike za nove ili postojeće zgrade, te dati preporuke za povećanje energetske učinkovitosti.

Postupak provedbe detaljnog energetskog pregleda zgrade rezultira dokumentom koji treba između ostalog da sadrži sljedeće informacije [88]:

- o građevinskim karakteristika zgrade u smislu toplinske zaštite ovojnice zgrade,
- karakteristike sustava klimatizacije, grijanja i hlađenja i ventilacije,
- karakteristike sustava za pripremu potrošne tople vode,
- karakteristike sustava potrošnje električne energije,
- podatke o potrošnji i troškovima energenata,
- mogućnosti promjene izvora energije,
- mogućnosti uporabe obnovljivih izvora energije i učinkovitih sistema,
- prijedlog ekonomski povoljnih mjera poboljšanja energetskih karakteristika zgrada, ostvarive uštede, procjenu investicije i razdoblje povrata investicije i
- završni izvještaj s preporukama za optimalni scenarij i redoslijed prioritetnih mjera koje će se implementirati kroz jednu ili više faza.

Prilikom izrade dokumenata DEA primjenjuju se strategije mjerenja i istraživanja pa u konačnici sadrži veliki skup pouzdanih podataka. Zbog navedenog pristupilo se traženju dokumenata DEA iz kojih bi se prikupljali i selektirali i neophodni podatci za ovo istraživanje. Sredinom 2019. godine upućen je zahtjev prema Fondu za zaštitu okoliša FBiH i poduzećima u FBiH koja su ovlaštena (ovlaštenje izdaje Federalno ministarstvo prostornog uređenja) za obavljanje poslova (usluga) izrade DEA za ustupanje dokumenata DEA zgrada namijenjenih za obrazovanje u FBiH.

Na upućeni zahtjev odgovorio je Fond za zaštitu okoliša FBiH koji je ustupio sve dokumente DEA s kojima je raspolagao i jedan dio poduzeća. Sveukupno je prikupljeno 185 dokumenata detaljnih energetskih pregleda zgrada namijenjenih za obrazovanje (zgrade osnovnih i srednjih škola) u FBiH koji predstavljaju bazu za izradu ovog istraživanja.

Dokumenti detaljnih energetskih pregleda (DEA) školskih zgrada u FBiH dobiveni su u pdf formatu i svrstani su po administrativnim cjelinama (kantonima/županijama) u FBiH. Iz navedenih dokumenata selektirani su podatci u jednu tablicu prikazanu u Prilogu 1 koja općenito sadrži podatke (osnovne i izvedene) svrstane u sljedećih nekoliko kategorija.

Opći podatci o lokaciji što uključuje:

- dodijeljenu šifru, naziv zgrade i lokaciju (grad/naselje),
- srednju godišnju temperaturu, srednju mjesečnu temperaturu u sezoni grijanja, srednju mjesečnu temperaturu najhladnijeg mjeseca i
- ISEE šifru i županiju kojoj pripadaju.

Podatci o broju djelatnika i korisnika.

Opći podatci o zgradi što uključuje:

- podatke o postojanju školske dvorane (budući da su školske zgrade i dvorane zasebni, ali su u smislu funkcije i zajedničkih sistema grijanja a time i uporabe energenata jedna cjelina, svi podatci o zgradi škole uključuju i podatke školske dvorane ukoliko ista postoji),
- klimatskoj regiji, godini izgradnje, kategoriji u odnosu na godinu izgradnje prema tipologiji javnih zgrada, godini značajne rekonstrukcije i
- godini izrade dokumenta DEA, izrađivaču DEA i godini energetske obnove (za zgrade za koje je izvršena obnova).

Geometrijski podatci o zgradi što uključuje podatke (ukoliko isti postoje):

- o tlocrtnoj bruto površini, broju etaža, neto površini,
- korisnoj površini (A_k), površini ovojnice grijanog dijela zgrade (A),
- volumen grijanog dijela zgrade (V_e), neto volumen grijanog zraka (V) i
- faktoru oblika zgrade (f_o) kao odnosu površine vanjske ovojnice grijanog dijela zgrade (A) i obujma grijanog dijela zgrade (V_e).

Podatci o energentu i režimu rada grijanja što uključuje podatke:

- o energentu koji se trenutno koristi (prije obnove) i
- broju sati rada sustava grijanja.

Podatci o stvarnoj potrošnji isporučene toplinske energije za grijanje što uključuje podatke:

- o stvarnoj prosječnoj godišnjoj potrošnji isporučene ($Q_{H,del}$) toplinske energije za grijanje (kWh/god) (podatci se odnose na prosječnu vrijednost 3 prethodne godine u odnosu na godinu izrade DEA),
- o specifičnoj (u odnosu na A_k) prosječnoj godišnjoj isporučenoj ($Q'_{H,del}$) toplinskoj energiji za grijanje (kWh/m^{2}god),
- o prosječnoj godišnjoj količini energenata za grijanje,
- o prosječnom godišnjem trošku energenata za grijanje (KM/god),
- o specifičnom prosječnom godišnjem trošku energenata za grijanje (KM/m^{2}god) i
- o prosječnom trošku energenata za grijanje po utrošenoj isporučenoj toplinskoj energiji (KM/kWh).

Podatci o stvarnoj potrošnji električne energije što uključuje podatke:

- o stvarnoj prosječnoj godišnjoj potrošnji električne energije ($E_{l,del}$) (kWh/god) (podatci se odnose na prosječnu vrijednost 3 prethodne godine u odnosu na godinu izrade DEA),
- o specifičnoj (u odnosu na A_k) prosječnoj godišnjoj električnoj energiji ($E'_{l,del}$) (kWh/m^{2}god),
- o prosječnom godišnjem trošku za električnu energiju (KM/god),
- o specifičnom prosječnom godišnjem trošku za električnu energiju (KM/m^{2}god) i
- o prosječnom trošku za električnu energiju po utrošenoj električnoj energiji (KM/kWh).

Podatci o toplinskim karakteristikama građevinskih dijelova ovojnice zgrade u trenutnom stanju (prije obnove) što uključuje podatke:

- o pojedinačnim površinama građevinskih dijelova ovojnice zgrade i ukupnim površinama svrstanim u četiri grupe, i to zidovi, podovi, stropovi i otvori,
- o koeficijentima prolaska topline (U) pojedinačnih građevinskih dijelova ovojnice zgrade,
- o prosječnim koeficijentima prolaska topline (U) svrstanim u četiri grupe, i to zidovi, podovi, stropovi i otvori,
- o prosječnom koeficijentu prolaska topline (U) za cjelokupni vanjsku ovojnicu zgrade,
- o koeficijentu transmisijske izmjene topline prema vanjskom okolišu (H_D),
- o koeficijentu transmisijske izmjene topline prema tlu (H_G),
- o koeficijentu transmisijske izmjene topline kroz negrijani prostor ili susjednim zgradama (H_u/H_A),
- o ukupnom koeficijentu transmisijske izmjene topline (H_{Tr}),
- o koeficijentu transmisijske izmjene topline u odnosu na ukupnu površinu ovojnice grijanog dijela zgrade ($H'_{Tr,adj}$),
- o dopuštenoj vrijednosti koeficijenta transmisijske izmjene topline u odnosu na ukupnu površinu ovojnice grijanog dijela zgrade ($H'_{Tr,dop}$),
- o usporedbi stvarne i dopuštene vrijednosti koeficijenta transmisijske izmjene topline,
- o ukupnom koeficijentu ventilacijske izmjene topline (H_{Ve}),
- o ukupnom koeficijentu izmjene topline ($H=H_{Tr}+H_{Ve}$) i
- o koeficijentu izmjene topline u odnosu na ukupnu površinu ovojnice grijanog dijela zgrade (H').

Napominje se kako su dokumenti detaljnih energetskih pregleda (DEA) izrađeni u razdoblju između 2012. i 2018. godine i u njima su korišteni dobiveni podatci od korisnika zgrada iz prethodne 3 godine u odnosu na godinu izrade DEA. U navedenim podatcima neke vrijednosti su izvedene veličine od osnovnih podataka kao npr. specifična prosječna godišnja isporučena toplinska energija za grijanje (kWh/m^{2}god) izračunata je kao količnik stvarne prosječne godišnje isporučene toplinske energije za grijanje (kWh/god) i korisne površine (A_k).

Ulazni podatci u Prilogu 1 vezani za novčane jedinice iskazani su u "konvertibilnim markama" (KM), ali će se rezultati ovog istraživanja koji uključuju novčane jedinice iskazivati u eurima (EUR) prema službenoj tečajnoj listi Centralne banke Bosne i Hercegovine gdje jedan euro iznosi 1,95583 konvertibilnih maraka.

Prema smjernicama za provođenje energetskih pregleda prilikom izrade DEA potrebno je utvrditi energetske karakteristike zgrada i stupanj ispunjenosti tih karakteristika u odnosu na zahtjeve propisane posebnim propisima koji su definirani kroz Pravilnik o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije. Ovim Pravilnikom se slijede zahtjevi Direktive 2002/91/EC Europskog Parlamenta o energetskim karakteristikama zgrada, a i između ostalog definiraju se [78]:

- tehnički zahtjevi u pogledu racionalne uporabe energije i toplinske zaštite koje treba ispuniti prilikom projektiranja i građenja novih zgrada i postojećih zgrada kod kojih se provode veće rekonstrukcije,
- metodologija za izračun potrebne toplinske energije za grijanje $Q_{H,nd}$ (kWh/god) u skladu s normom BAS EN ISO 13790:2005, metoda proračuna po mjesecima i
- održavanje zgrade u odnosu na racionalnu uporabu energije i toplinsku zaštitu.

Neki od tehničkih zahtjeva za racionalnu uporabu energije i toplinsku zaštitu zgrada propisani su [78]:

- najvećom dopuštenom godišnjom potrebnom toplinskom energijom za grijanje po jedinici korisne površine zgrade, odnosno po jedinici obujma grijanog dijela zgrade,
- najvećim dopuštenim koeficijentom transmisijskog toplinskog gubitka po jedinici površine ovojnice grijanog dijela zgrade,
- najvećim dopuštenim koeficijentima prolaza topline pojedinih građevinskih dijelova ovojnice zgrade,
- smanjenjem utjecaja toplinskih mostova na ovojnici zgrade,
- najvećom dopuštenom kondenzacijom vodene pare unutar građevinskog dijela zgrade i
- sprečavanjem površinske kondenzacije vodene pare.

Prema prethodno navedenom, pri izradi DEA potrebno je proračunati godišnju potrebnu ($Q_{H,nd}$) toplinsku energiju za grijanje za postojeće stanje i usporediti je s dopuštenom vrijednosti iste prema odredbama Pravilnika o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije kako bi se utvrdio stupanj ispunjenosti. Također prilikom izrade DEA proračunava se i godišnja isporučena ($Q_{H,del}$) toplinska energija za grijanje (kWh/god) te se ista uspoređuje sa stvarnom potrošnjom isporučene toplinske energije kako bi se zaključilo je li postignuta toplinska ugodnost.

Proračunske vrijednosti godišnje potrebne ($Q_{H,nd,cal}$) toplinske energije za grijanje godišnje i isporučene ($Q_{H,del,cal}$) toplinske energije za grijanje za svaku zgradu unesene su u tablicu u prilogu 1 zajedno s izvedenim vrijednostima (izvedene vrijednosti predstavljaju ukupne vrijednosti podijeljene s korisnom površinom zgrade, odnosno svedene na jedinicu mjere korisne površine zgrade).

Modelirana (proračunska) potrošnja potrebne ($Q_{H,nd,cal}$) energije za grijanje za postojeće stanje (prije obnove) što uključuje podatke:

- o proračunski potrebnoj (korisnoj) ($Q_{H,nd,cal}$) godišnjoj toplinskoj energiji za grijanje (kWh/god),
- o proračunski specifičnoj (u odnosu na A_k) potrebnoj ($Q'_{H,nd,cal}$) godišnjoj toplinskoj energiji za grijanje (kWh/m^{2}god),
- o dopuštenoj potrebnoj ($Q'_{H,nd}$) godišnjoj toplinskoj energiji za grijanje (kWh/m^{2}god) definiranoj prema odredbama Pravilnika o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije ("Sl. novine FBiH", br. 49/09),
- o usporedbi proračunske i dopuštene vrijednosti potrebne godišnje toplinske energije za grijanje,
- o proračunski specifičnoj (u odnosu na V_e) potrebnoj ($Q''_{H,nd}$) godišnjoj toplinskoj energiji za grijanje (kWh/m^{3}god) ,
- o dopuštenoj potrebnoj ($Q''_{H,nd}$) godišnjoj toplinskoj energiji za grijanje (kWh/m^{3}god) definiranoj prema odredbama Pravilnika o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije ("Sl. novine FBiH", br. 49/09),
- o usporedbi proračunske i dopuštene vrijednosti potrebne ($Q''_{H,nd}$) godišnje toplinske energije za grijanje i
- o energetskom razredu u odnosu na o specifičnu potrebnu ($Q'_{H,nd,cal}$) godišnju toplinsku energiju za grijanje (kWh/m^{2}god).

Modelirana (proračunska) potrošnja godišnje isporučene ($Q_{H,del,cal}$) toplinske energije za grijanje za postojeće stanje (prije obnove) što uključuje podatke:

- o proračunski isporučenoj ($Q_{H,del,cal}$) godišnjoj toplinskoj energiji za grijanje (kWh/god),

- o proračunski specifičnoj (u odnosu na A_k) isporučenoj ($Q'_{H,del,cal}$) godišnjoj toplinskoj energiji za grijanje (kWh/m^{2}god),
- o usporedbi stvarne i proračunske isporučene godišnje toplinske energije za grijanje,
- o proračunskom trošku za proračunsku isporučenu ($Q_{H,del,cal}$) godišnju toplinsku energiju za grijanje (KM/god) za trenutni energent koji se koristi,
- o proračunskom specifičnom trošku za proračunsku isporučenu ($Q'_{H,del,cal}$) godišnju toplinsku energiju za grijanje (KM/m^{2}god) i
- o proračunskoj godišnjoj količini energenata za grijanje (za energente za koje je moguće odrediti).

Dokumenti DEA sadrže prijedlog mjera za poboljšanje toplinskih karakteristika građevinskih dijelova ovojnice zgrada, termotehničkih mjera za poboljšanje sustava grijanja, zamjene energenta i zamjene rasvjetnih tijela. Također vrši se jednostavna tehnoekonomska analiza predviđenih mjera određivanjem razdoblja povrata investicije i indeksom uštede. Ovaj dio podataka nije prezentiran u radu.

4. Statistička analiza prikupljenih podataka o energetskim karakteristikama školskih zgrada u FBiH iz uzorka

4.1 Statistički uzorak

U prethodnom poglavlju opisan je način prikupljanja podataka iz dokumenata detaljnih energetskih pregleda školskih zgrada u FBiH, a u ovom poglavlju slijedi obrada i statistička analiza s interpretacijom prikupljenih podataka. Statistički skup ili uzorak predstavljaju statističke jedinice, u ovom slučaju školske zgrade za osnovne i srednje škole u FBiH (u nastavku školske zgrade u FBiH). Ovim istraživanjem prikupljeno je 185 dokumenata detaljnih energetskih pregleda školskih zgrada u FBiH koji su svrstani su po administrativnim cjelinama (kantonima/županijama) u FBiH i koji predstavljaju osnovni statistički uzorak za prikupljanje podataka o obilježjima statističkog skupa. Na slici 4.1 prikazane su lokacije školskih zgrada iz uzorka. Crvenom bojom označene su škole u regiji ''sjever'' (RS FBiH), a zelenom bojom škole koje pripadaju regiji ''jug'' (RJ FBiH).

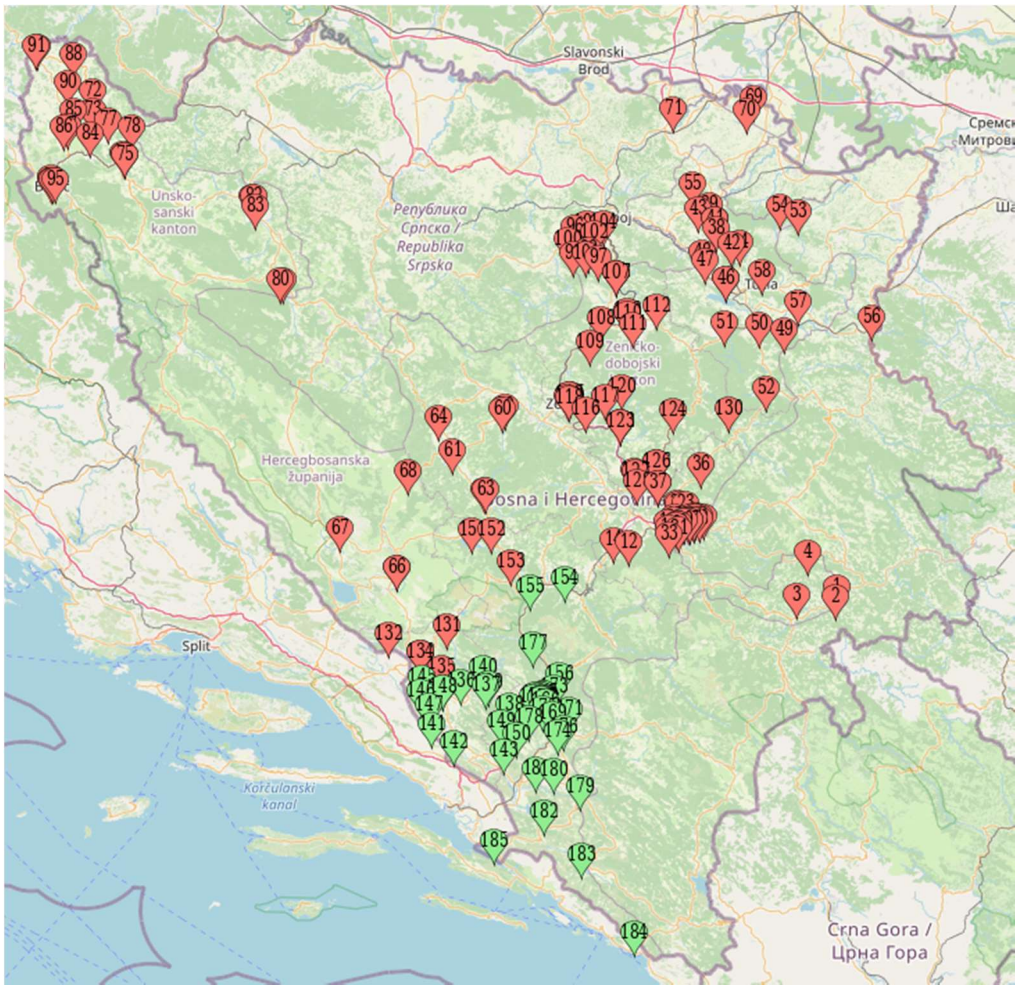

Slika 4.1 Lokacije školskih zgrada u FBiH iz uzorka

Ukupan broj zgrada za obrazovanje u FBiH prema tipologiji javnih zgrada BiH (TJZ) iznosi 1.455, od čega u klimatskoj regiji sjever (RS) 1.192 zgrade ili 81,9% a u klimatskoj regiji jug (RJ) 263 zgrade ili 18,1%. Ukupan broj školskih zgrada u FBiH iz uzorka iznosi 185, od čega u klimatskoj regiji sjever 138 školskih zgrada ili 74,6% a u klimatskoj regiji jug 47 školskih zgrada ili 25,4%.

Gledajući zemljopisno, može se vidjeti kako su školske zgrade iz uzorka prostorno zastupljene po cijeloj FBiH uključujući klimatske regije ''sjever'' i ''jug''. U tablici 4.1 prikazana je razdioba statističkog uzorka u odnosu na ukupan broj zgrada namijenjenih za obrazovanje u FBiH prema podatcima iz dokumenta tipologija javnih zgrada (TJZ) i iz uzorka, zatim razdioba prema korisnoj površini (A_k), i razdioba u odnosu na razdoblje izgradnje i po klimatskim regijama.

Tablica 4.1 Podatci o broju školskih zgrada u FBiH iz uzorka i korisnim površinama (A_k) u odnosu na razdoblje izgradnje i klimatske regije

		Broj zgrada u FBiH prema TJZ	Broj zgrada u FBiH iz uzorka	Udio (%) broja zgrada iz uzorka u ukupnom broju zgrada prema TJZ	Ukupna korisna površina grijanog dijela Ak (m2) u FBiH prema TJZ	Ukupna korisna površina grijanog dijela Ak (m2) u FBiH iz uzorka	Udio (%) površine grijanog dijela Ak iz uzorka prema ukupnoj grijanoj površini prema TJZ
do 1945	FBiH	109	14	12,8%	105.089	29.446	28,0%
	RS FBiH	89	10	11,2%	85.806	24.820	28,9%
	RJ FBiH	20	4	20,0%	19.282	4.626	24,0%
od 1946 do 1965	FBiH	498	53	10,6%	466.471	128.310	27,5%
	RS FBiH	408	40	9,8%	382.169	105.192	27,5%
	RJ FBiH	90	13	14,4%	84.302	23.119	27,4%
od 1966 do 1973	FBiH	250	36	14,4%	355.042	69.070	19,5%
	RS FBiH	205	28	13,7%	291.135	56.424	19,4%
	RJ FBiH	45	8	17,8%	63.908	12.646	19,8%
od 1974 do 1987	FBiH	343	73	21,3%	570.257	185.714	32,6%
	RS FBiH	281	56	19,9%	467.178	145.706	31,2%
	RJ FBiH	62	17	27,4%	103.078	40.008	38,8%
od 1988 do 2009	FBiH	212	8	3,8%	198.070	14.808	7,5%
	RS FBiH	174	4	2,3%	162.567	10.987	6,8%
	RJ FBiH	38	4	10,5%	35.503	3.820	10,8%
od 2010	FBiH	43	1	2,3%	31.913	4.030	12,6%
	RS FBiH	35	0	0,0%	25.976	0	0,0%
	RJ FBiH	8	1	12,5%	5.937	4.030	67,9%
UKUPNO	FBiH	1.455	185	12,7%	1.726.842	431.378	25,0%
	RS FBiH	1.192	138	11,6%	1.414.831	343.129	24,3%
	RJ FBiH	263	47	17,9%	312.010	88.249	28,3%

Ukupan udio školskih zgrada u FBiH iz uzorka (185) u odnosu na ukupan broj zgrada za obrazovanje u FBiH prema TJZ (1.455) iznosi 12,7% (185/1.455). Ako se pogleda udio korisne površine (A_k) školskih zgrada u FBiH iz uzorka (431.378) u odnosu na ukupnu korisnu površinu zgrada za obrazovanje u FBiH prema TJZ (1.726.842) udio iznosi približno 25,0% (431.378/1.726.842), odnosno površinski predstavlja približno ¼ ukupne korisne površine svih školskih zgrada u FBiH. Navedeno upućuje da se u uzorku nalaze školske zgrade većih korisnih površina.

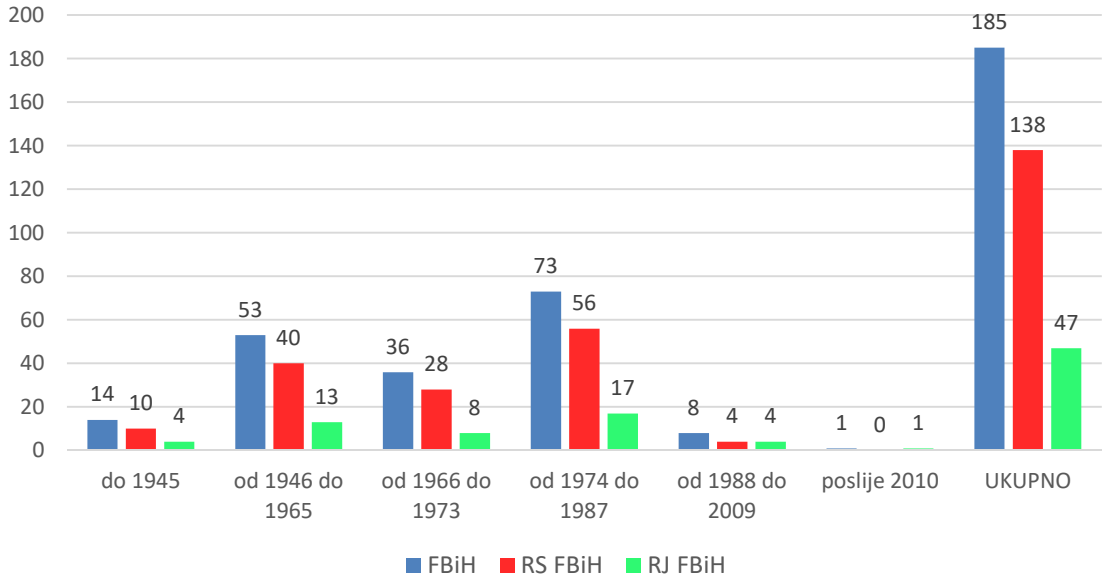

Slika 4.2 Raspodjela broja školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije

Na slici 4.2 može se vidjeti kako je najveći broj analiziranih školskih zgrada u FBiH iz uzorka izgrađen u razdoblju od 1974. do 1987. godine, a zatim slijedi razdoblje od 1946. do 1965. godine. U razdoblju izgradnje poslije 2010. godine u statističkom uzorku nalazi samo 1 zgrada. U odnosu na klimatske regije udio broja zgrada iz klimatske regije ''sjever'' u odnosu na ukupan statistički uzorak iznosi od približno 74,6% (135/185), odnosno približno ¾ ukupnog uzorka što je i očekivano jer su u klimatskoj regiji sjever (RS) smještene 1.192 školske zgrade (od ukupno 1.455) ili 81,9%. Na slici 4.3 prikazana je razdioba ukupne korisne površine školskih zgrada u FBiH iz uzorka .

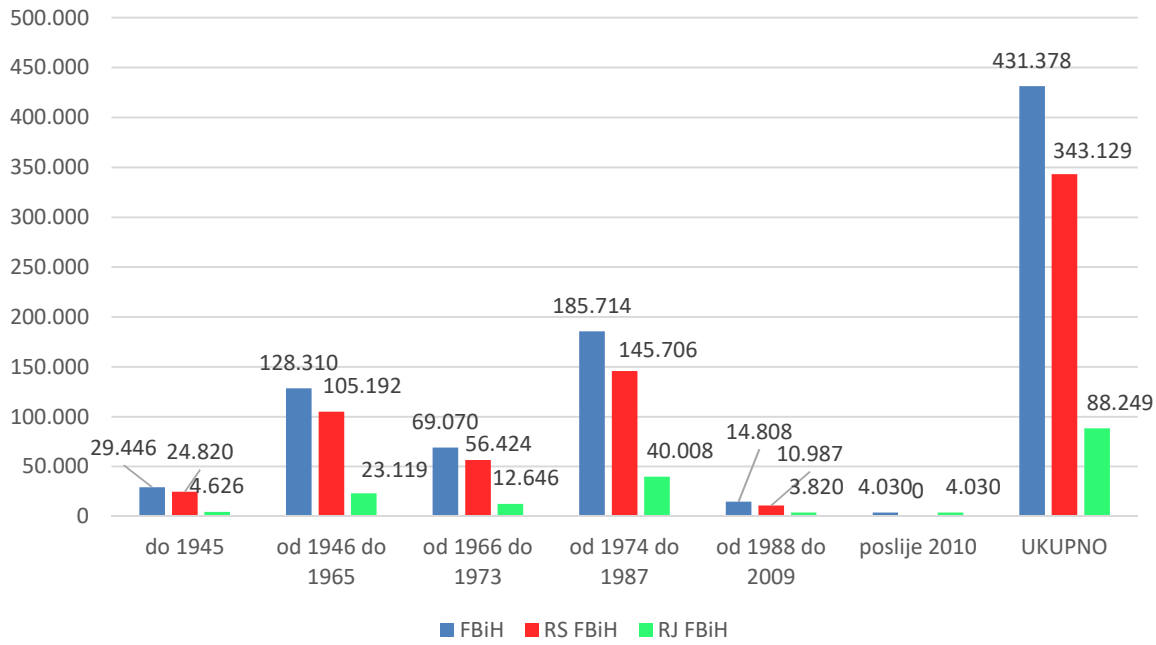

Slika 4.3 Raspodjela ukupne korisne površine (A_k) školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije

Sa slike 4.3 može se vidjeti kako se najveća korisna površine (A_k) analiziranih školskih zgrada u FBiH iz uzorka nalazi u razdoblju od 1974. do 1987. godine što odgovara najvećem broju školskih zgrada izgrađenih u tom razdoblju, a zatim slijedi razdoblje od 1946. do 1965. godine.

Za prikupljene i odabrane podatke iz seta podataka izvršena je osnovna statistička analiza (deskriptivna statistika). Obilježja jedinica statističkog skupa su svojstva po kojima su te jedinice međusobno slične ili po kojima se razlikuju. Zadaća deskriptivne statistike je opisati, urediti i sažeti rezultate istraživanja kako bi bili pregledniji, razumljiviji i pogodniji za interpretaciju i daljnju analizu [89].

Izvršena je interpretacija dobivenih rezultata, te su tablično i grafički predstavljene i prezentirane osnovne karakteristike skupa podataka koristeći sljedeće statističke parametre i oznake [89-91]:

- broj (x_i) predstavlja pojedinačne vrijednosti kvantitativnog obilježja u statističkom skupu,
- broj (n) predstavlja broj jedinica iz statističkog skupa (uzorka),
- minimalna vrijednost ($x_{\min}$) predstavlja najmanju vrijednost kvantitativnog obilježja u statističkom skupu,
- maksimalna vrijednost ($x_{\max}$) predstavlja najveću vrijednost kvantitativnog obilježja u statističkom skupu,

- raspon varijacije (R_x) predstavlja raspon ili razliku između najveće i najmanje vrijednosti kvantitativnog obilježja u statističkom skupu i određuje se prema sljedećem izrazu:

$$R_x = x_{\max} - x_{min} \tag{4.1}$$

- aritmetička sredina ($\overline{X}$) ili prosječna vrijednost određuje se prema sljedećem izrazu:

$$\overline{X} = \frac{\sum_{i=1}^{n} x_i}{n} \tag{4.2}$$

- medijan (M_e) je srednja položajna vrijednost koja ima svojstvo da se lijevo i desno nalazi jednak broj podataka zadanog niza. Određuje se prema sljedećim izrazima:

$$M_e = \frac{x'_{\frac{n}{2}} + x'_{\frac{n}{2}+1}}{2} \text{ za parno } n \tag{4.3}$$

$$M_e = x'_{\frac{n}{2}+1} \text{ za neparno } n \tag{4.4}$$

gdje su x' vrijednosti poredane po veličini,

- standardna devijacija (σ_x) je apsolutna mjera disperzije vrijednosti i predstavlja prosječno odstupanje od aritmetičke sredine. Određuje se prema sljedećem izrazu:

$$\sigma_x = \sqrt{\frac{\sum_{i=1}^{n} (x_i - \overline{X})^2}{n}} \tag{4.5}$$

- koeficijent varijacije (V) je relativna mjera disperzije i predstavlja odnos standardne devijacije i aritmetičke sredine. Određuje se prema sljedećem izrazu:

$$V = \frac{\sigma_x}{\overline{X}} x100\% \tag{4.6}$$

varijabilnost do 10% je vrlo slaba, od 10% do 30% je slaba, od 30% do 50% umjerena, od 50% do 70% je jaka a preko 70% vrlo jaka (što upućuje da razdioba nije jednolika),

- donji kvartal (q_1) predstavlja položajnu vrijednost od koje 25% podataka ima manju ili njemu jednaku vrijednost,
- gornji kvartal (q_3) koji predstavlja položajnu vrijednost od koje 75% podataka ima manju ili njemu jednaku vrijednost, odnosno od koje 25% podataka ima veću vrijednost i

- koeficijent kvartilne devijacije (V_q) predstavlja relativnu mjeru disperzije središnjih 50% podataka skupa i određuje se prema sljedećem izrazu:

$$V_q = \frac{q_3 - q_1}{q_3 + q_1} 100\% \tag{4.7}$$

Varijabilitet V_q od 0% do 10% je vrlo slab, od 10% do 20% relativno slab, od 20% do 30% umjeren, od 30% do 50% relativno jak, a od 50% do 100% vrlo jak. Mjere disperzije ukazuju na reprezentativnost srednjih vrijednosti. Manja mjera disperzije znači veću reprezentativnost srednje vrijednosti i obrnuto. Pomoću mjera disperzije uspoređuju se razlike u varijabilitetu dvaju ili više distribucija. Ukoliko se radi o istim obilježjima (sa sličnim vrijednostima) za usporedbu se mogu koristiti apsolutne mjere disperzije. Ako se radi o distribucijama različitih obilježja (ili istih obilježja različitih modaliteta) za usporedbu varijabiliteta obavezno se koriste relativne mjere disperzije [90].

4.2 Analiza karakteristika školskih zgrada u FBiH iz uzorka

Za procjenu energetskih karakteristika (performansi) zgrada koriste se metodologije inženjerskih proračuna, simulacija, statističkih metoda i strojnog učenja. Iako je cilj energetske procjene zgrada u pravilu povezan s pokušajima poboljšanja njihovih performansi [31], u ovom istraživanju je definirana metodologija ocjene energetskih karakteristika školskih zgrada u FBiH iz uzorka analiziranjem njihovih karakteristika, potrošnje i troškova energije. Statistička analiza podataka iz uzorka o karakteristikama školskih zgrada u FBiH iz uzorka u ovom poglavlju sažeto je prikazana u tablicama i slikama.

Ocjena energetskih karakteristika zgrade je mjerilo kvalitete zgrade u odnosu na energetsku učinkovitost. Što je niži energetski razredi to je zgrada lošija u smislu postignutih toplinskih karakteristika, ali isto tako veća je prilika za smanjenje emisije ugljika i poboljšanje energetskih karakteristika zgrade. Međutim, ocjena ne daje informacije o tome kako zgrada funkcionira u stvarnim uvjetima uporabe [84] jer je energetski razred određen prema standardiziranim uvjetima korištenja zgrade i proračunskim vrijednostima potrošnje energije.

Kako bi se procijenile energetske karakteristike postojećeg stanja školskih zgrada u FBiH, izvršena je usporedba izračunatih ili izmjerenih vrijednosti pojedinih karakteristika s referentnim ili dopuštenim vrijednostima. Izračunate ili izmjerene vrijednosti su preuzete iz dokumenata detaljnih energetskih pregleda (DEA), a referentne vrijednosti su određene ili definirane prema važećim zakonskim propisima.

4.2.1 Analiza općih i geometrijskih karakteristika školskih zgrada u FBiH iz uzorka

Jedan od parametara za procjenu energetskih potreba za grijanje i hlađenje je broj stupanj dana grijanja (SDG). Pretpostavlja se da su energetske potrebe za zgradu proporcionalne razlici između osnovne temperature i srednje temperature vanjskog zraka. Ukupan broj godišnjih stupanj dana grijanja (SDG) izračunava se pomoću slijedećeg izraza [92]:

$$SDG = \sum_{dani} \left(T_{un} - T_v \right)^{+} \tag{4.8}$$

gdje su:

- SDG broj stupanj dana grijanja,
- T_{un} unutarnja projektirana temperature i
- T_v srednja dnevna temperatura zraka vani.

Znak plus iznad zagrade ukazuje da se broje samo pozitivne vrijednosti.

Podatci o broju stupanj dana grijanja (SDG) preuzeti su iz Pravilnika o minimalnim zahtjevima za energetskim značajkama zgrada ("Sl. novine FBiH", br. 81/2019) za uvjete kada srednja vanjska temperatura padne ispod 12°C [81]. Za lokacije za koje ne postoji SDG izvršena je interpolacija u odnosu na najbližu ili odgovarajuću postaju. Na slici 4.4 prikazan je histogram pripadajućih stupanj dana grijanja (SDG) školskih zgrada u FBiH iz baze podataka koja se koristi u ovom istraživanju.

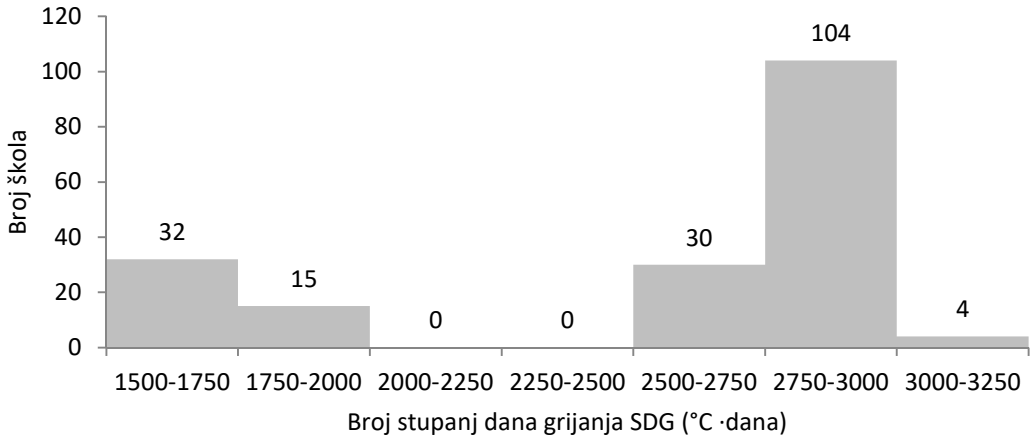

Slika 4.4 Histogram broja školskih zgrada u FBiH iz uzorka u odnosu na broj stupanj dana grijanja (SDG)

Na slici 4.4 se mogu vidjeti dva dijela. Prvi manji dio se odnosi na 47 školskih zgrada iz uzorka smještenih u regiji jug (RJ), a drugi dio na 138 školskih zgrada smještenih u regiji sjever (RS). Prosječna vrijednost broja stupnja dana grijanja (SDG) u FBiH iznosi 2.567 °C·dana, u regiji sjever (RS) iznosi 2.842 °C·dana a u regiji jug (RJ) FBiH iznosi 1.759 °C·dana što predstavlja oko 62% u odnosu na vrijednost u RS FBiH. Najveći broj školskih zgrada iz uzorka (104) prostorno se nalazi u zoni gdje se broj SDG kreće u rasponu od 2.750 do 3.000 °C·dana.

Od parametara koji definiraju zauzetost prostora analizirani su broj djelatnika i broj korisnika odnosno učenika koji pohađaju škole. Na slici 4.5 prikazan je broj školskih zgrada u odnosu na broj korisnika kao i broj školskih zgrada u odnosu na veličinu korisnog prostora (A_k) po korisniku. Prosječna površina po korisniku iznosi 5,77 (m^2/korisniku), dok prosječni broj korisnika po jedinici korisne površine iznosi 0,24 (korisnik/m^2).

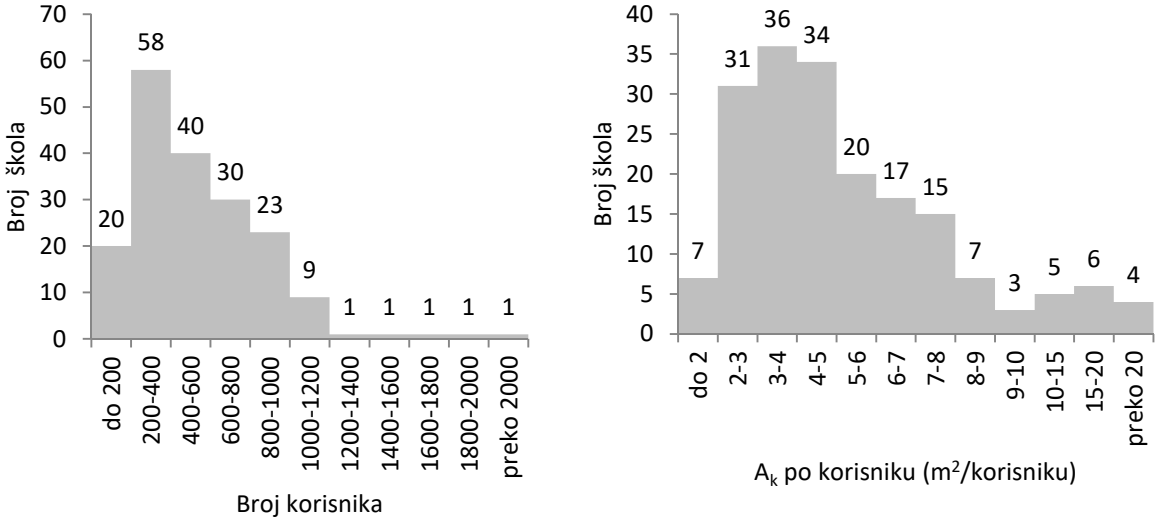

Slika 4.5 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na broj korisnika i korisnoj površini (A_k) po korisniku

Na slici 4.6 su prikazani opći podatci o školskim zgradama u FBiH iz uzorka što uključuje godinu izgradnje kako bi se odredio broj škola prema razdoblju izgradnje i starost iste u odnosu na 2020. godinu koja je uzeta kao referentna.

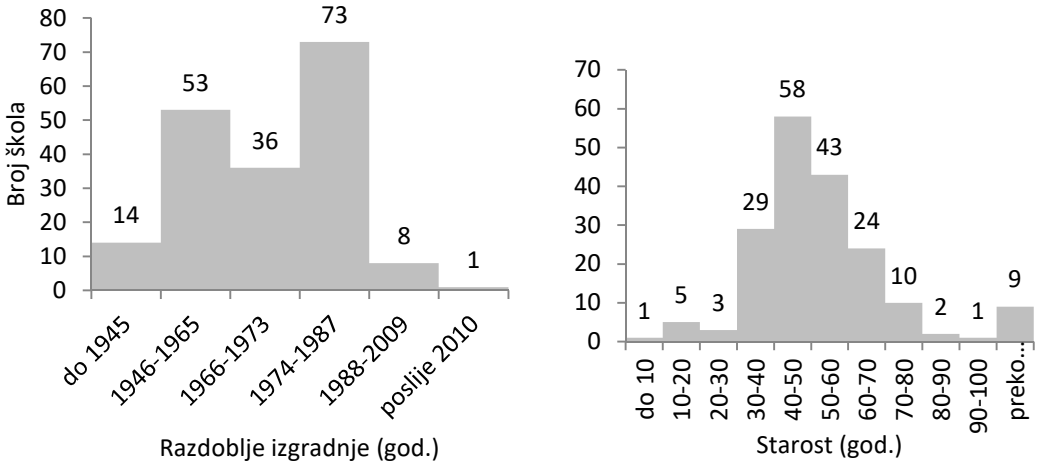

Slika 4.6 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i starost

U odnosu na razdoblje izgradnje 50% školskih zgrada u FBiH iz uzorka je izgrađeno u razdoblju od 1960. do 1979. godine, a u razdoblju između 1946. i 1988. godine nalazi se 162 škole, odnosno 87,6% uzorka što približno odgovara podatcima iz tablice 4.2. Prosječna starost iznosi preko 53 godine, a 9 analiziranih školskih zgrada starije je od 100 godina.

Geometrijski podatci o zgradi predstavljaju veličinu, oblik i kompaktnost, a iskazani su preko korisne površine (A_k), površine ovojnice grijanog dijela zgrade (A) i volumena grijanog dijela zgrade (V_e). Na slici 4.7 prikazani su histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na korisnu površinu (A_k) i volumen grijanog zraka (V_e).

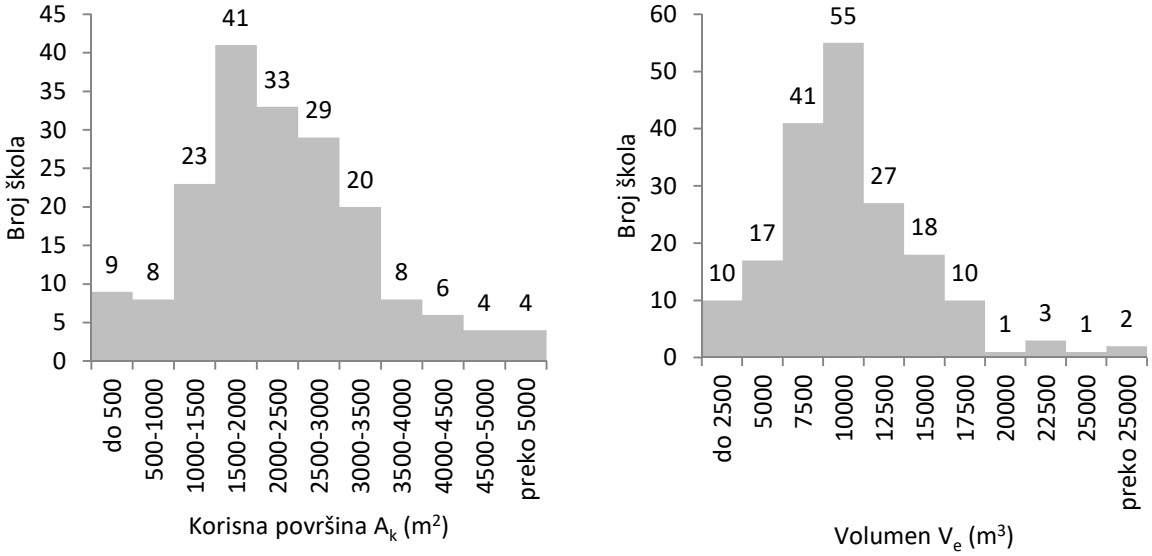

Slika 4.7 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na korisnu površinu (A_k) i volumen grijanog zraka (V_e)

68,1% školskih zgrada iz uzorka ima korisnu površinu A_k u rasponu od 1.000,00 do 3.000,00 m^2, a prosječna korisna površina školskih zgrada zajedno sa školskim dvoranama iznosi oko 2.332,00 m^2. Prosječni volumen grijanog dijela zgrade V_e iznosi 9.079,00 m^3. Prosječna površina ovojnice A (uključujući pojedinačne dijelove zidove, podove, stropove i otvore) iznosi 4.707,00 m^2. U rasponu površine ovojnice od 2.000,00 do 6.000,00 m^2 nalazi se 135 škola ili 73,0%, a u rasponu od 3.440,00 do 5.706,00 m^2 ili 50% površina ovojnica školskih zgrada iz uzorka. Na slici 4.8 prikazana je raspodjela broja školskih zgrada u FBiH iz uzorka u odnosu na površinu ovojnice.

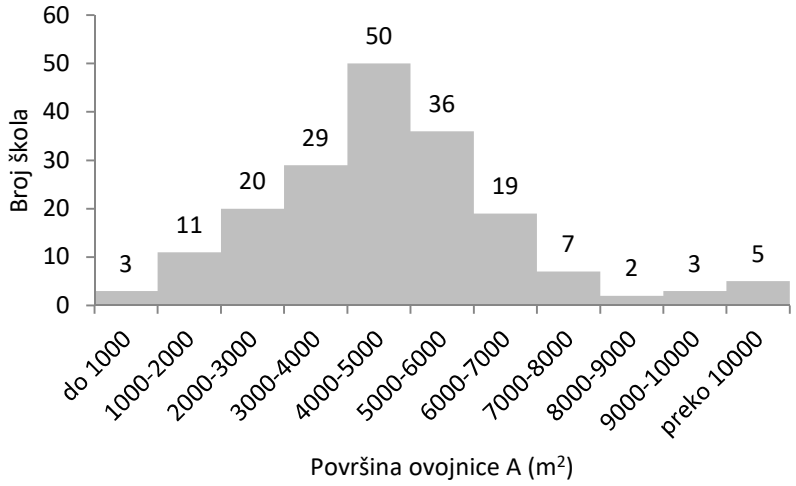

Slika 4.8 Histogram broja školskih zgrada u FBiH iz uzorka u odnosu na površinu ovojnice (A)

Pravilnik o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije kao i ostali pravilnici u BiH i zemljama okruženja definiraju varijablu za procjenjivanje kompaktnosti faktora oblika označenu s f_o koja predstavlja odnos površine ovojnice grijanog dijela (A) i volumena grijanog zraka (V_e) i naziva se faktor oblika [78]. Manja površina ovojnice potrebna za određeni volumen ukazuje na kompaktniju površinu i ima niže zahtjeve za potrošnjom energije za grijanje.

Prema standardu EN 15217 faktor oblika (f) definira odnos površine ovojnice grijanog dijela (A) i korisne površine grijanog dijela (A_k), a faktor kompaktnosti (c) definira odnos površine ovojnice (A) i volumena grijanog zraka (V_e). U istraživanju značaja faktora oblika zgrada navodi se kako je faktor oblika označen s (f_0) jedan od parametara koji ima utjecaj na pokazatelje energetske učinkovitosti [93].

Kako bi se istražili utjecaji gore navedena dva faktora na pokazatelje energetske učinkovitosti u ovom istraživanju će se analizirati faktor f_o koji predstavlja kompaktnost zgrade (u nastavku faktor kompaktnosti) i faktor oblika f (u nastavku faktor oblika), sukladno nomenklaturi prema standardu EN 15217. Na slici 4.9 prikazani su histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na faktor oblika (f) i faktor kompaktnosti (f_o).

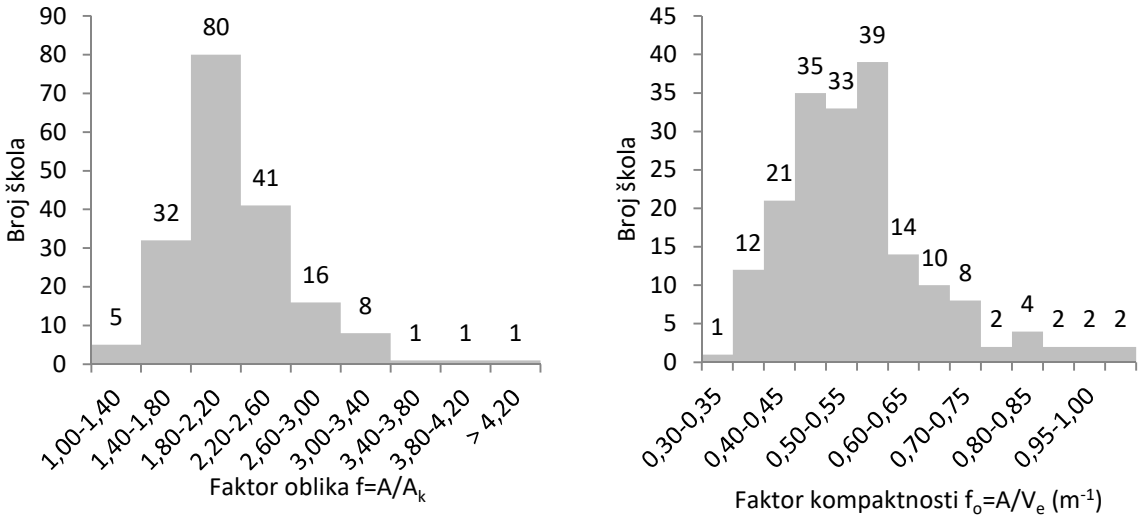

Slika 4.9 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na faktore oblika (f) i kompaktnosti (f_o)

Prosječna vrijednost faktora kompaktnosti f_o iznosi 0,56 (m^{-1}) a u rasponu od 0,40 do 0,60 (m^{-1}) nalazi se 128 škola, odnosno 69,2% uzorka. Prema tablici 3.7 prosječna vrijednost faktora kompaktnosti f_o zgrada za obrazovanje u FBiH iznosi 0,55 (m^{-1}) tako da dobivena prosječna vrijednost faktora kompaktnosti f_o školskih zgrada u FBiH iz uzorka od 0,56 neznatno odstupa. Najveći broj škola ima vrijednost faktora oblika f u rasponu od 1,80 do 2,20 a u rasponu od 1,40 do 2,60 nalazi se 153 škole, odnosno 82,7% školskih zgrada u FBiH iz uzorka, dok prosječna vrijednost iznosi 2,17.

Izvršena je analiza općih i geometrijskih podataka školskih zgrada u FBiH iz uzorka, po razdobljima izgradnje i klimatskim regijama te su prosječni podatci prikazani u tablici 4.2.

Tablica 4.2 Podatci o prosječnim vrijednostima geometrijskih karakteristika (starost, korisna površina (A_k), volumen grijanog zraka (V_e), površina ovojnice (A), faktor oblika (f) i faktor kompaktnosti (f_o) školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije

ŠKOLSKE ZGRADE U FBIH IZ UZORKA		Prosječna starost zgrada (god)	Prosječna korisna površina grijanog dijela zgrade A_k (m^2)	Prosječni volumen grijanog zraka zgrade V_e (m^3)	Prosječna površina ovojnice grijanog dijela zgrade A (m^2)	Prosječna vrijednost faktora oblika zgrade $f=A/A_k$	Prosječna vrijednost faktora kompaktnosti zgrade $f_0=A/V_e$ (m^{-1})
do 1945	FBiH	104	2.103	8.181	4.567	2,28	0,58
	RS FBiH	104	2.482	9.552	5.411	2,24	0,58
	RJ FBiH	105	1.156	4.753	2.455	2,39	0,58
od 1946 do 1965	FBiH	63	2.421	9.970	4.862	2,12	0,52
	RS FBiH	64	2.630	10.684	5.254	2,11	0,52
	RJ FBiH	63	1.778	7.772	3.654	2,18	0,52
od 1966 do 1973	FBiH	51	1.919	7.276	3.948	2,17	0,57
	RS FBiH	51	2.015	7.528	4.127	2,11	0,56
	RJ FBiH	50	1.581	6.394	3.322	2,37	0,62
od 1974 do 1987	FBiH	41	2.544	9.532	5.094	2,20	0,57
	RS FBiH	41	2.602	9.492	5.135	2,17	0,57
	RJ FBiH	41	2.353	9.663	4.959	2,30	0,57
od 1988 do 2009	FBiH	20	1.851	7.194	3.342	2,07	0,53
	RS FBiH	21	2.747	10.275	4.492	1,64	0,45
	RJ FBiH	19	955	4.112	2.191	2,49	0,62
od 2010	FBiH	6	4.030	21.383	8.464	2,10	0,40
	RS FBiH	-	-	-	-	-	-
	RJ FBiH	6	4.030	21.383	8.464	2,10	0,40
UKUPNO	FBiH	53	2.332	9.079	4.707	2,17	0,56
	RS FBiH	54	2.486	9.466	4.966	2,13	0,55
	RJ FBiH	51	1.878	7.942	3.945	2,30	0,57

Za opće i geometrijske podatke školskih zgrada u FBiH iz uzorka prikazana je analiza deskriptivne statistike u tablici 4.3, čiji su parametri opisani u poglavlju 4.1, a uključuje sljedeće pokazatelje:

- broj jedinica iz statističkog skupa (n),
- najmanju vrijednost u statističkom skupu ($x_{\min}$),
- najveću vrijednost u statističkom skupu ($x_{\max}$),
- raspon između najveće i najmanje vrijednosti (R_x),
- prosječnu vrijednost ($\overline{X}$),
- srednju položajnu vrijednost, medijan (M_e),

- standardnu devijaciju (σ_x),
- koeficijent varijacije (V),
- donji kvartil (q_1),
- gornji kvartil (q_3) i
- koeficijent kvartilne devijacije (V_q).

Tablica 4.3 Podatci deskriptivne statistike za opće i geometrijske podatke školskih zgrada u FBiH iz uzorka u odnosu na godinu izgradnje, starost, korisnu površinu (A_k), volumen grijanog zraka (V_e) površinu ovojnice(A), faktor oblika (f) i faktor kompaktnosti (f_o)

Varijabla	n	x_{min}	x_{max}	R_x	$\bar{X}$	M_e	σ_x	V	q_1	q_3	V_q
Godina izgradnje zgrade (god.)	185	1886	2014	128	1966,9	1971,0	19,54	1,0%	1.960	1.979	0,5%
Starost zgrade (god.)	185	6,0	134,0	128,00	53,2	50,0	19,56	36,8%	41,0	60,0	18,8%
Korisna površina zgrade A_k (m^2)	185	83,6	7710,0	7626,4	2331,8	2204,6	1177,7	50,5%	1.579,0	2.906,2	29,6%
Volumen grijanog zraka zgrade V_e (m^3)	185	325,3	27354,5	27029,2	9079,0	8387,5	4566,9	50,3%	6.354,8	11.249,0	27,8%
Površina ovojnice zgrade A (m^2)	185	327,9	11459,9	11132,0	4707,0	4681,5	1942,5	41,3%	3.439,7	5.706,4	24,8%
Faktor oblika zgrade f	185	1,18	6,38	5,20	2,17	2,09	0,55	25,5%	1,87	2,35	11,4%
Faktor kompaktnosti zgrade f_o (m^{-1})	185	0,32	1,01	0,69	0,56	0,53	0,12	21,9%	0,48	0,60	11,5%

4.2.2 Analiza karakteristika građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka

Prilikom prikupljanja i odabira podataka iz dokumenata detaljnih energetskih pregleda (prilog 1) određene su ukupne i prosječne površine građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka svrstane u četiri grupe, i to zidovi, podovi, stropovi i otvori.

Zidovi uključuju površine svih vanjskih zidova (zidova prema vanjskom zraku), zidova prema tlu kao i zidova prema negrijanim prostorima. Podovi predstavljaju površine u kontaktu s tlom, odnosno podove na tlu i podove prema negrijanim podrumima. Stropovi uključuju površine stropova iznad grijanog prostora prema tavanu, prema ravnim (prohodnim i neprohodnim) ili kosim krovovima, stropove iznad vanjskog zraka i stropove prema negrijanim prostorima. Otvori uključuju transparentne elemente na ovojnici (najčešće na zidovima), a to su prozori, vrata i krovni prozori. U tablici 4.4 prikazane su prosječne vrijednosti površina građevinskih dijelova ovojnice i njihovih udjela u ukupnoj površini ovojnice.

Tablica 4.4 Podatci o prosječnim površinama građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije

ŠKOLSKE ZGRADE U FBIH IZ UZORKA		Prosj. površina zidova (m^2)	Udio (%) površine zidova u ukupnoj površini ovojnice	Prosj. površina podova (m^2)	Udio (%) površine podova u ukupnoj površini ovojnice	Prosj. površina stropova (m^2)	Udio (%) površine stropova u ukupnoj površini ovojnice	Prosj. površina otvora (m^2)	Udio (%) površine otvora u ukupnoj površini ovojnice	Prosj. površina ovojnice A (m^2)
do 1945	FBiH	1.703	37,4%	1.166	25,6%	1.224	26,9%	456	10,0%	4.567
	RS FBiH	1.937	36,0%	1.416	26,3%	1.481	27,5%	552	10,3%	5.386
	RJ FBiH	1.117	45,5%	541	22,0%	583	23,7%	215	8,8%	2.455
od 1946 do 1965	FBiH	1.548	31,8%	1.254	25,8%	1.437	29,6%	622	12,8%	4.862
	RS FBiH	1.666	31,7%	1.367	26,0%	1.562	29,7%	658	12,5%	5.254
	RJ FBiH	1.185	32,4%	905	24,8%	1.053	28,8%	510	14,0%	3.654
od 1966 do 1973	FBiH	1.205	30,5%	1.062	26,9%	1.177	29,8%	502	12,7%	3.948
	RS FBiH	1.248	30,3%	1.117	27,1%	1.221	29,6%	539	13,1%	4.125
	RJ FBiH	1.057	31,8%	871	26,2%	1.022	30,8%	373	11,2%	3.322
od 1974 do 1987	FBiH	1.404	27,6%	1.431	28,1%	1.610	31,6%	645	12,7%	5.094
	RS FBiH	1.412	27,5%	1.437	28,0%	1.630	31,8%	650	12,7%	5.129
	RJ FBiH	1.379	27,8%	1.409	28,4%	1.542	31,2%	628	12,7%	4.959
od 1988 do 2009	FBiH	934	27,9%	964	28,8%	1012	30,2%	432	12,9%	3.342
	RS FBiH	1.205	26,8%	1.327	29,5%	1.346	30,0%	614	13,7%	4.492
	RJ FBiH	662	30,2%	601	27,4%	677	30,9%	250	11,4%	2.190
od 2010	FBiH	2236	26,4%	2559	30,2%	3038	35,9%	631	7,5%	8.464
	RS FBiH	-	-	-	-	-	-	-	-	-
	RJ FBiH	2236	26,4%	2559	30,2%	3038	35,9%	631	7,5%	8.464
UKUPNO	FBiH	1.414	30,1%	1.274	27,1%	1.429	30,4%	587	12,5%	4.707
	RS FBiH	1.484	29,9%	1.347	27,2%	1.508	30,4%	622	12,5%	4.962
	RJ FBiH	1.206	30,6%	1.060	26,9%	1.195	30,3%	485	12,3%	3.945

Prosječna površina zidova u uzorku iznosi 1.414 m^2, podova 1.274 m^2, stropova 1.429 m^2 i otvora 587 m^2. U odnosu na ukupan uzorak školskih zgrada u FBiH površine građevinskih dijelova ovojnice u regiji jug FBiH imaju nešto manju prosječnu površinu u odnosu na zgrade smještene u regiji sjever FBiH.

Sa slike 4.10 može se vidjeti kako udio površina zidova opada a udio površine otvora i stropova raste za zgrade građene nakon 1945. godine. Gledajući ukupan uzorak oko 30 % ukupne površine ovojnice predstavljaju površine vanjskih zidova i stropova, zatim slijedi površina podova s oko 27 % i na kraju površina otvora s oko 13 %.

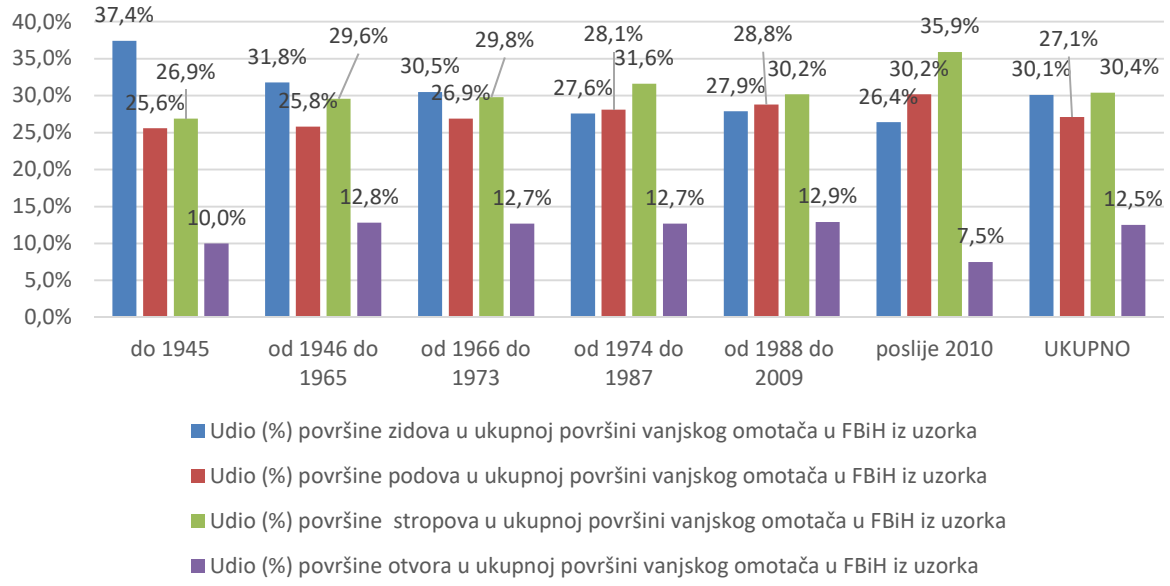

Slika 4.10 Udio pojedinačnih površina građevinskih dijelova u ukupnoj površini ovojnice školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje

U tablici 4.5 su prikazane vrijednosti deskriptivne statistike, a na slici 4.11 histogrami prosječnih površina građevinskih dijelova ovojnice (zidova, podova, stropova, otvora i ukupne ovojnice) školskih zgrada u FBiH iz uzorka. U rasponu površine zidova od 500,00 do 2.000,00 m^2 nalazi se 145 škola ili 78,4%, a u rasponu od 1.005,00 do 1.725,00 m^2 ili 50% površina zidova iz uzorka. U rasponu površine podova od 500,00 do 2.000,00 m^2 nalazi se 152 škole ili 82,2%, a u rasponu od 900,00 do 1.600,00 m^2 ili 50% površina podova iz uzorka. U rasponu površine stropova od 500,00 do 2.000,00 m^2 nalazi se 147 škola ili 79,5%, a u rasponu od 1.026,00 do 1.786,00 m^2 ili 50% površina stropova iz uzorka. U rasponu površine otvora od 200,00 do 800,00 m^2 nalazi se 134 škole ili 72,4%, a u rasponu od 394,00 do 735,00 m^2 ili 50% površina otvora iz uzorka. Prosječna površina otvora iznosi 587,00 m^2, a prosječna površina ovojnice iznosi 4.707,00 m^2.

Tablica 4.5 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema prosječnim površinama građevinskih dijelova ovojnice (zidova, podova, stropova, otvora i ukupne ovojnice)

Varijabla	n	x_{min}	x_{max}	R_x	$\bar{X}$	M_e	σ_x	V	q_1	q_3	V_q
Pros. površina zidova (m^2)	185	105,7	4065,5	3959,8	1413,6	1327,1	640,7	45,3%	1.005,3	1.725,0	26,4%
Pros. površina podova (m^2)	185	100,1	3608,4	3508,3	1274,2	1158,1	606,7	47,6%	901,4	1.600,0	27,9%
Pros. površina stropova (m^2)	185	100,1	4251,5	4151,4	1428,7	1333,4	672,0	47,0%	1.026,5	1.786,3	27,0%
Pros. površina otvora (m^2)	185	22,0	1635,2	1613,2	587,0	555,5	299,3	51,0%	394,0	735,1	30,2%
Pros. površina ovojnice A (m^2)	185	327,9	11459,9	11132,0	4707,0	4681,5	1942,5	41,3%	3.439,7	5.706,4	24,8%

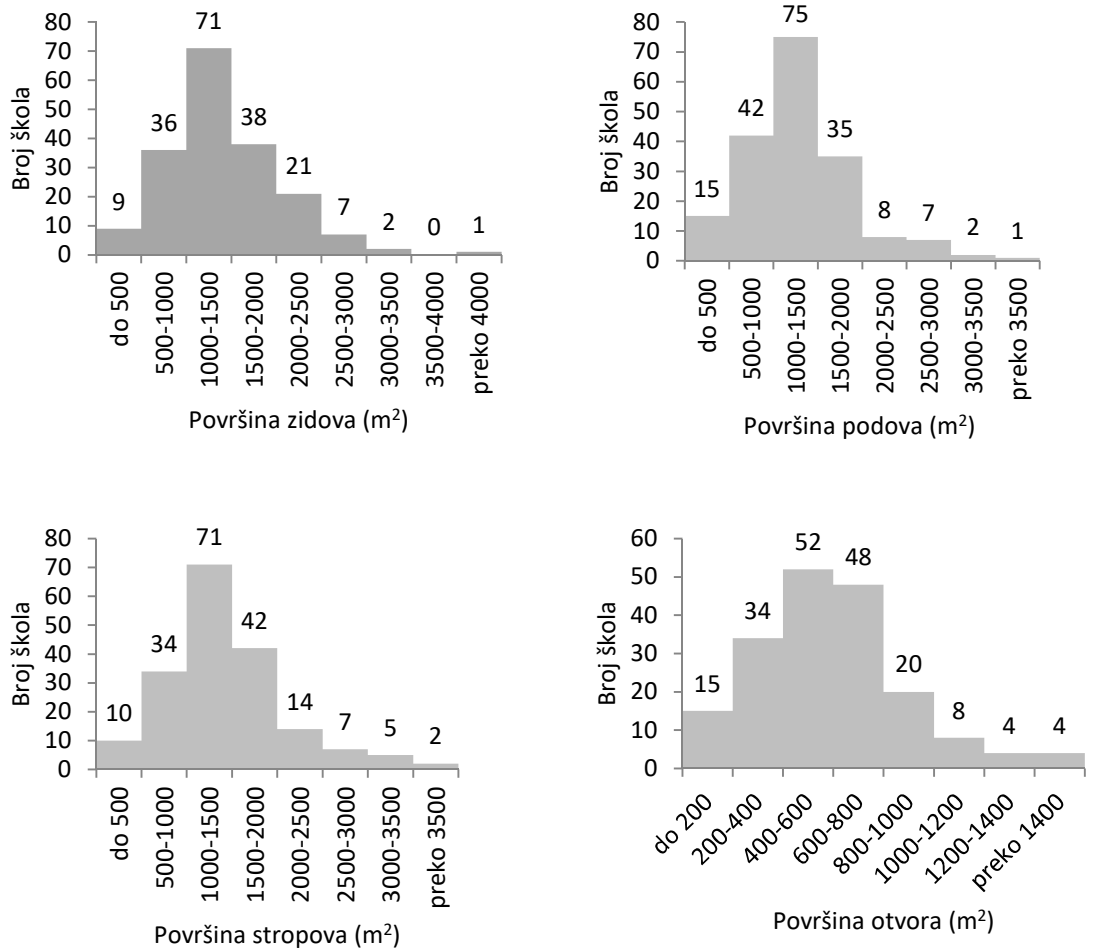

Slika 4.11 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na površinu zidova, podova, stropova i otvora ovojnice

Sljedeći korak u istraživanju je bio da se iz dokumenata detaljnih energetskih pregleda za svaki pojedinačni građevinski dio ovojnice, prikupe podatci o karakteristikama građevinskih dijelova ovojnice što uključuje sastav konstrukcije istog (vrsta materijala i debljina slojeva) te vrijednosti izračunatih koeficijenata prolaska topline ''U'' (U-vrijednost) izraženim u W/m^{2}K.

Prolaz topline kroz konstrukciju ovisi o ugrađenim materijalima, njihovoj toplinskoj provodljivosti i debljini njihovih slojeva. Poredak slojeva u sklopu ne utječe na prolaz topline, važan postaje kada se govori o akumulaciji topline i toplinskom odazivu zgrade na promjene toplinskih odnosa u okolini. Podatci o toplinskoj propusnosti ovojnice zgrade neophodni su za kvantificiranje gubitaka kroz njega. U-vrijednost ovojnice zgrade igra ključnu ulogu za procjenu toplinskih svojstava ovojnice [94].

Za procjenu i proračun U-vrijednosti postojećih zgrada na raspolaganju su četiri pristupa [95]:

1. procjena na temelju podataka dobivenih povijesnom analizom zgrada ili analogija sa sličnim i jednakim zgradama korištenjem specifičnih tehničkih baza podataka,

2. procjena na temelju nazivnih projektnih podataka,
3. procjena na temelju stvarnih podataka dobivenih identifikacijom strukture (metoda uzorkovanja ili endoskop) i
4. na licu mjesta pomoću mjerenja protoka topline (*Heat Flow Meters, HFM*).

Podatci o prosječnim U-vrijednostima pojedinih građevinskih dijelova ovojnice analiziranih školskih zgrada u FBiH iz uzorka prilikom izrade DEA dobiveni su proračunima na temelju podataka dobivenih povijesnom analizom zgrada i razdoblja izgradnje. Kvaliteta toplinske zaštite ovojnice zgrade mjeri se na temelju U-vrijednosti građevinskog dijela ovojnice zgrade. Prosječna U-vrijednost za slučajeve kada za zgradu imamo više vrsta pojedinih građevinskih dijelova ovojnice (npr. kada imamo više vrsta zidova različitih karakteristika) se određuje prema slijedećem izrazu:

$$U_{GDO} = \frac{\sum A_{GDOi} \bullet U_{GDOi}}{\sum A_{GDOi}} \tag{4.9}$$

gdje su:

- U_{GDO} prosječna U-vrijednost građevinskog dijela ovojnice,
- A_{GDOi} površina građevinskog dijela ovojnice "i" i
- U_{GDOi} U-vrijednost građevinskog dijela ovojnice "i".

U tablici 4.6 su prikazane vrijednosti deskriptivne statistike, na slici 4.12 su prikazani histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na U-vrijednosti (W/m^{2}K) građevinskih dijelova ovojnice (zidova, podova, stropova i otvora).

Tablica 4.6 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema U - vrijednostima (W/m^{2}K) građevinskih dijelova ovojnice (zidova, podova, stropova, otvora i ukupne ovojnice)

Varijabla	n	x_{min}	x_{max}	R_x	$\bar{X}$	M_e	σ_x	V	q_1	q_3	V_q
U - vrijednosti zidova (W/m^{2}K)	185	0,25	2,81	2,56	1,48	1,43	0,46	30,8%	1,20	1,77	19,2%
U - vrijednosti podova (W/m^{2}K)	185	0,34	4,37	4,03	1,95	1,65	1,14	58,8%	0,98	2,67	46,4%
U - vrijednosti stropova (W/m^{2}K)	185	0,32	4,81	4,48	1,82	1,57	1,06	58,0%	1,02	2,53	42,5%
U - vrijednosti otvora (W/m^{2}K)	185	1,41	5,07	3,66	2,90	2,97	0,71	24,5%	2,38	3,38	17,3%
U - vrijednosti ovojnice (W/m^{2}K)	185	0,51	3,31	2,81	1,87	1,86	0,55	29,6%	1,44	2,26	22,0%

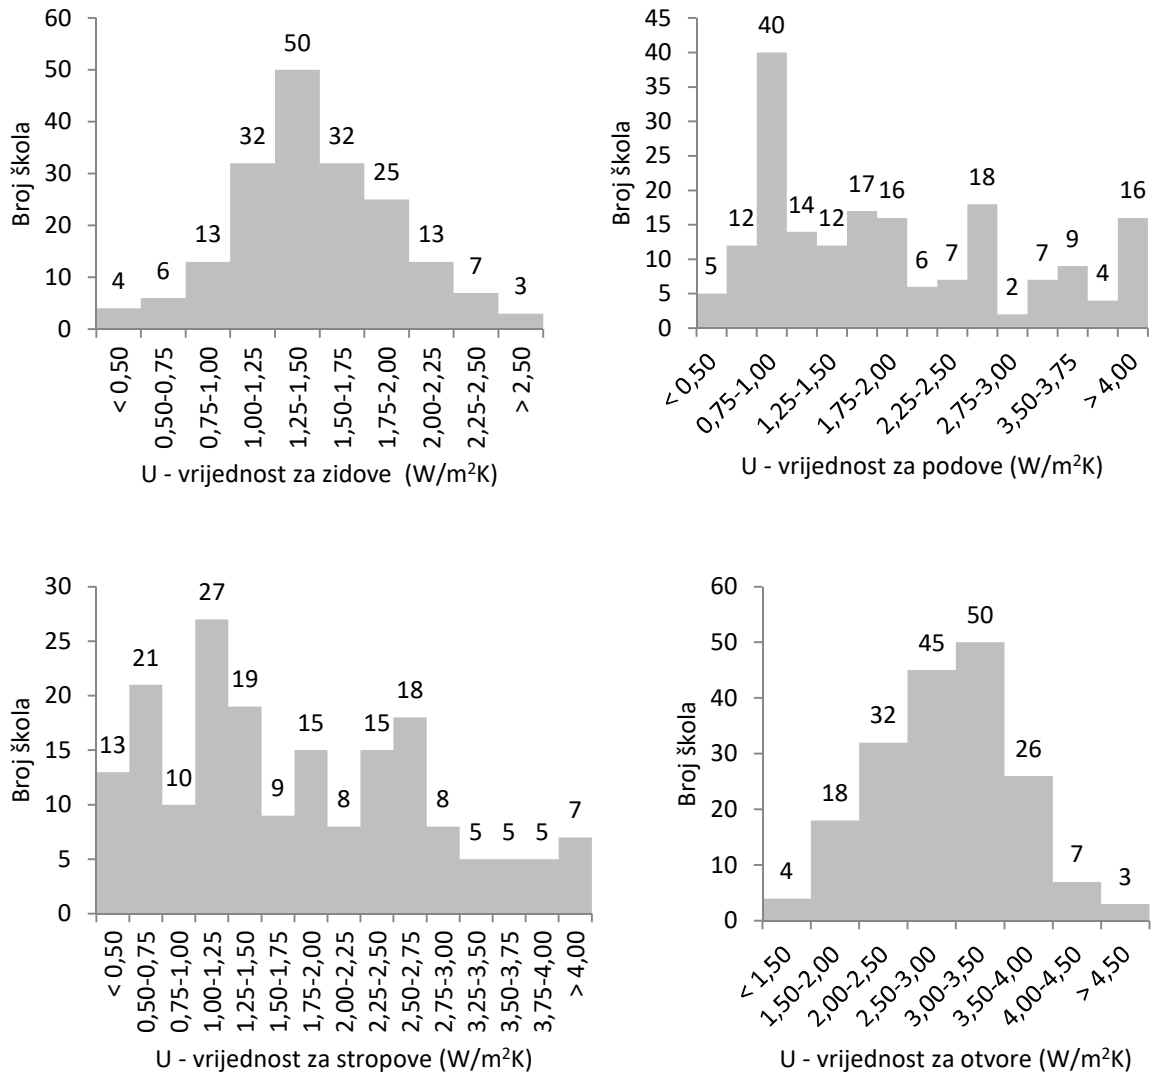

Slika 4.12 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na U - vrijednosti zidova, podova, stropova i otvora ovojnice

Analizirajući sliku 4.12 i tablicu 4.6 sa stajališta U - vrijednosti (W/m^{2}K) građevinskih dijelova ovojnice (zidova, podova, stropova i otvora) školskih zgrada u FBiH iz uzorka može se uočiti umjerena do srednja disperzija vrijednosti za zidove, otvore i ukupnu ovojnicu dok se za podove i stropove primjećuje veća disperzija, odnosno razdioba nije jednolika. Razlog tomu leži u činjenici različitih pristupa u proračunu U - vrijednosti (W/m^{2}K) za podove i stropove što je utjecalo na disperziju navedenih podataka. Kod proračuna U-vrijednosti podova neki autori su u izračun uzimali sve slojeve podne konstrukcije a neki su uzimali samo slojeve podne konstrukcije do sloja hidroizolacije. Kod proračuna U-vrijednosti stropova (najvećim dijelom to su stropovi prema tavanima ili ravnim krovovima) neki autori su uzimali u obzir otpor koji pruža prostor tavana dok drugi nisu.

Prosječna U - vrijednost za zidove iznosi 1,48 W/m^{2}K, a u rasponu vrijednosti od 1,00 do 2,00 W/m^{2}K nalazi se 139 školskih zgrada ili 75,1%, a u rasponu od 1,20 do 1,77 W/m^{2}K nalazi se 50% školskih zgrada iz uzorka. U - vrijednosti za podove imaju jaku disperziju (koeficijent varijacije iznosi preko 50%), prosječna vrijednost iznosi 1,95 W/m^{2}K, a u rasponu 0,98 do 2,67 W/m^{2}K nalazi se 50% škola iz uzorka. U - vrijednosti za stropove također imaju veću disperziju, prosječna vrijednost iznosi 1,82 W/m^{2}K, a u rasponu 1,02 do 2,53 W/m^{2}K nalazi se 50% školskih zgrada iz uzorka. Analizirajući U - vrijednosti za otvore najveći broj školskih zgrada iz uzorka (50) ima prosječnu vrijednost koeficijenta prolaska topline ''U'' u rasponu od 3,00 do 3,50 W/m^{2}K, u rasponu vrijednosti od 2,00 do 4,00 W/m^{2}K nalaze se 153 ili 82,7%, a u rasponu od 2,38 do 3,38 W/m^{2}K nalazi se 50% školskih zgrada iz uzorka. Prosječna U - vrijednost otvora iznosi 2,90 W/m^{2}K.

Analizirajući U – vrijednosti za ukupnu ovojnicu prosječna vrijednost iznosi 1,87 W/m^{2}K, a u rasponu vrijednosti od 1,00 do 2,50 W/m^{2}K nalaze se 154 škole ili 83,2%, a u rasponu od 1,44 do 2,26 W/m^{2}K nalazi se 50% školskih zgrada iz uzorka. U – vrijednosti za ovojnicu imaju slabu disperziju (koeficijent varijacije iznosi do 30%). Na slici 4.13 je prikazana histogram U-vrijednosti ovojnice.

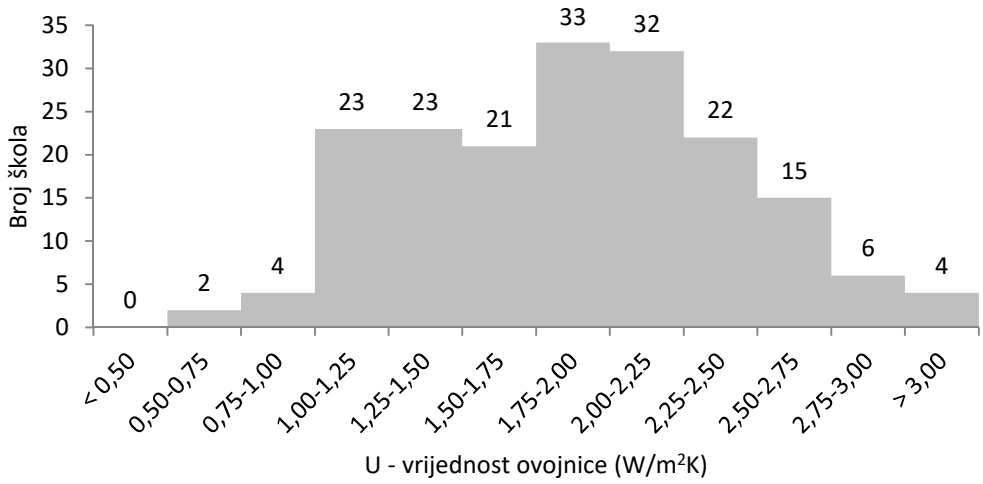

Slika 4.13 Histogram broja školskih zgrada u FBiH iz uzorka u odnosu na U – vrijednosti ovojnice

Na slici 4.14 su prikazana promjena prosječnih U – vrijednosti građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje.

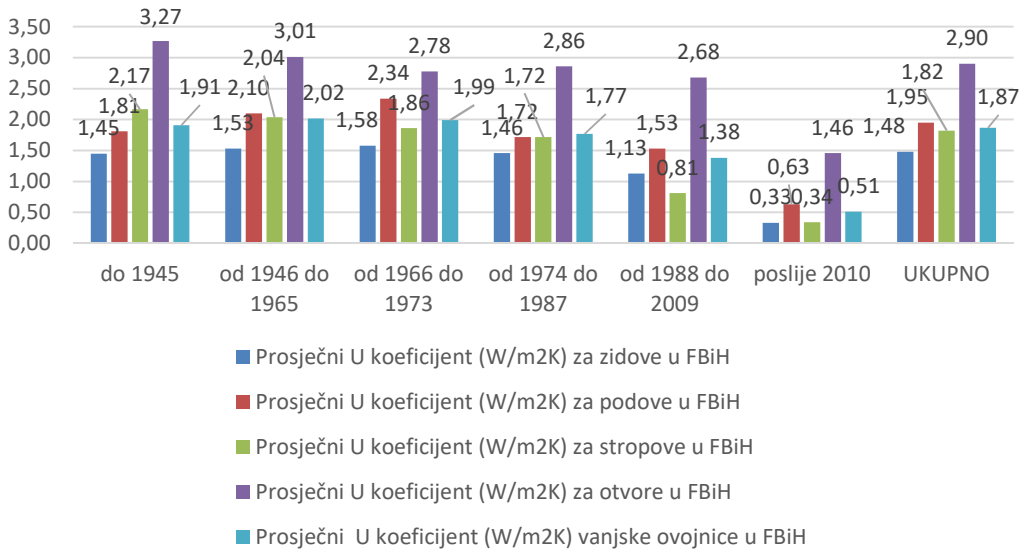

Slika 4.14 Prosječne U – vrijednosti građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje

Analizirajući promjenu vrijednosti prosječnih koeficijenata prolaska topline ''U'' za vanjske zidove po razdobljima izgradnje može se primijetiti utjecaj promjene debljine zida. Zgrade građene do 1945. godine imaju masivne vanjske zidove izrađene od pune opeke debljine 48 cm ili od prirodnog kamena i obostrano ožbukane. Nakon tog razdoblja došlo je do promjene tehnologija građenja i uvođenja armiranog betona tako da zidovi postaju sve tanji što je u utjecalo na povećanje vrijednosti koeficijenata prolaska topline ''U'' za zidove. Tek od 1970-tih godina i stupanja na snagu propisa o minimalnoj toplinskoj zaštiti počinju se graditi zidovi sa slojevima termoizolacije što je u utjecalo na smanjenje vrijednosti koeficijenata prolaska topline ''U'' za zidove.

Također analizirajući vrijednosti prosječnih koeficijenata prolaska topline ''U'' za otvore može se vidjeti utjecaj promjene i poboljšanja tehnologije i kvalitete istih. Vanjski otvori do 1970-tih godina uglavnom su bili izrađeni od drvenih okvira, dvostruki, sa spojenim krilima i jednostrukim staklom. Uvođenjem dvostrukog stakla ili termo stakla a od 1980-tih godina dijelom okvira od PVC-a i aluminija dolazi do poboljšanja toplinskih svojstava i smanjenja vrijednosti koeficijenata prolaska topline ''U'' za otvore.

Značajniji pad vrijednosti prosječnih koeficijenata prolaska topline ''U'' vidljiv je nakon 2009. godine kad se počinju izgrađivati zgrade s znatno boljim toplinskim karakteristikama (vanjski zidovi se izvode toplinskom izolacijom najčešće od EPS-a u tzv. ETICS sustavima, otvori se izvode od PVC profila s dvostrukim ili trostrukim toplinsko-izolacijskim staklima, toplinski se izoliraju zadnje stropne ploče). Razlozi za navedeno leže u širenju znanja i svijesti o potrebi i dobrobitima toplinske zaštite zgrada uz stupanje na snagu novih propisa kojima se definiraju oštriji zahtjevi za toplinskom zaštitom i proračunom zgrade kao jedinstvene cjeline.

U tablici 4.7 dan je sažeti prikaz prosječnih U - vrijednosti građevinskih elemenata dijelova svrstanih u četiri grupe, i to zidovi, podovi, stropovi i otvori. Dobiveni su na temelju poznatih pojedinačnih vrijednosti koeficijenta prolaska topline za svaki pojedinačni građevinski dio ovojnice i udjelu pojedinačnih površina u ukupnoj površini pojedine grupe. Također, prikazane su prosječne U - vrijednosti za cijelu ovojnicu u odnosu na razdoblje izgradnje i klimatske regije.

Tablica 4.7 Podatci o prosječnim U - vrijednostima građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije

ŠKOLSKE ZGRADE U FBIH IZ UZORKA		Prosječni U - koeficijent (W/m²K) za zidove	Prosječni U - koeficijent (W/m²K) za podove	Prosječni U - koeficijent (W/m²K) za stropove	Prosječni U - koeficijent (W/m²K) za otvore	Prosječni U - koeficijent ovojnice (W/m²K)
do 1945	FBiH	1,45	1,81	2,17	3,27	1,91
	RS FBiH	1,38	1,97	2,26	3,35	1,95
	RJ FBiH	1,63	1,43	1,93	3,06	1,80
od 1946 do 1965	FBiH	1,53	2,10	2,04	3,01	2,02
	RS FBiH	1,47	2,03	1,87	3,04	1,93
	RJ FBiH	1,71	2,32	2,58	2,91	2,27
od 1966 do 1973	FBiH	1,58	2,34	1,86	2,78	1,99
	RS FBiH	1,58	2,52	1,80	2,80	2,02
	RJ FBiH	1,57	1,75	2,07	2,73	1,89
od 1974 do 1987	FBiH	1,46	1,72	1,72	2,86	1,77
	RS FBiH	1,41	1,66	1,73	2,91	1,76
	RJ FBiH	1,61	1,93	1,68	2,69	1,83
od 1988 do 2009	FBiH	1,13	1,53	0,81	2,68	1,38
	RS FBiH	1,25	1,69	1,02	2,72	1,51
	RJ FBiH	1,01	1,37	0,61	2,64	1,25
od 2010	FBiH	0,33	0,63	0,34	1,46	0,51
	RS FBiH	-	-	-	-	-
	RJ FBiH	0,33	0,63	0,34	1,46	0,51
UKUPNO	FBiH	1,48	1,95	1,82	2,90	1,87
	RS FBiH	1,45	1,97	1,80	2,95	1,87
	RJ FBiH	1,55	1,89	1,90	2,76	1,88

Ukupna prosječna U - vrijednost (W/m²K) ovojnice u regiji sjever iznosi 1,87 W/m²K, a u regiji jug 1,88 W/m²K. Stoga se može zaključiti kako analizirane zgrade sa stajališta toplinskih karakteristika ovojnice imaju slične karakteristike (jer su građeni istom tehnologijom i materijalima) bez obzira na lokaciju i klimatske regije u FBiH iako su zahtjevi za toplinskom zaštitom različiti u odnosu na klimatske regije (u klimatskoj regiji sjever FBiH zahtjevi za U – vrijednost imaju niže vrijednosti nego u regiji jug).

Energetske karakteristike ovojnice određene su usporedbom dobivenih proračunatih U-vrijednosti s dopuštenim vrijednostima prema propisima čime se utvrđuje stupanj ispunjenosti istih kao i kvaliteta ovojnice sa stajališta toplinske zaštite u trenutnom stanju. U tablici 4.8 dane su dopuštene U - vrijednosti prema Pravilniku o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije iz 2009. godine i prema novom Pravilniku o minimalnim zahtjevima za energijskim karakteristikama zgrada iz 2019. godine koji ima pooštrene zahtjeve.

Tablica 4.8 Podatci o prosječnim U - vrijednostima građevinskih dijelova ovojnice školskih zgrada u FBiH iz uzorka i vrijednosti prema pravilnicima

R. br.	Dio ovojnice	Prosječna U - vrijednost (W/m²K)	Pravilnik iz 2009. [78]		Pravilnik iz 2019. [81]	
			$\Theta_{e,mj} \leq 3°C$	$\Theta_{e,mj} > 3°C$	$\Theta_{e,mj} \leq 3°C$	$\Theta_{e,mj} > 3°C$
1.	Vanjski zidovi	1,48	0,45	0,60	0,35	0,45
2.	Podovi	1,95	0,50	0,50	0,40	0,50
3.	Stropovi	1,82	0,30	0,40	0,25	0,30
4.	Otvori	2,90	1,80	1,80	1,40	1,60

gdje je $\Theta_{e,mj}$ srednja mjesečna temperatura najhladnijeg mjeseca u godini.

Prosječne U-vrijednosti višestruko premašuju dopuštene vrijednosti što ukazuje na nedostatak slojeva toplinske izolacije i u najvećoj mjeri utječu na ukupne toplinske transmisijske gubitke. Zbog navedenog U-vrijednosti građevinskih dijelova ovojnice predstavljaju jedno od temeljnih obilježja ili značajnih varijabli energetskih karakteristika koje utječu na potrošnju toplinske energije a time i na troškove toplinske energije zgrada.

Prema Pravilniku [78] proračunavaju se vrijednosti koeficijenta transmisijske izmjene topline H_{tr} (W/K) prema normi EN 13789 i slijedećem izrazu [96]:

$$H_{tr} = H_D + H_U + H_G + H_A \left[W / K \right] \tag{4.10}$$

gdje su:

- H_D koeficijent transmisijske izmjene topline prema vanjskom okolišu (W/K),
- H_U koeficijent transmisijske izmjene topline kroz negrijani prostor (W/K),
- H_G koeficijent transmisijske izmjene topline prema tlu (W/K) i
- H_A koeficijent transmisijske izmjene topline prema susjednoj zgradi (W/K).

Pri proračunu koeficijenta transmisijske izmjene topline prema vanjskom okolišu H_D uzima se utjecaj toplinskih mostova preko dodatka ΔU_{TM} na koeficijente prolaska topline ''U'' građevinskih dijelova ovojnice u iznosu od 0,10 W/m^{2}K za loša toplinska rješenja i 0,05 W/m^{2}K za dobra toplinska rješenja.

U-vrijednosti građevinskih dijelova ovojnice i njihove površine najviše utječu na vrijednost koeficijenta transmisijske izmjene topline H_{tr}. Na Slici 4.15 prikazane su prosječne vrijednosti koeficijenta transmisijske izmjene topline H_{tr} školskih zgrada u FBiH iz uzorka. Najveći transmisijski gubitci u iznosu od oko 90% odnose se na gubitke prema vanjskom okolišu kroz zidove, stropove i otvore, a zatim prema tlu u iznosu oko 9% preko poda na tlu i samo oko 1% na gubitke preko negrijanih prostora.

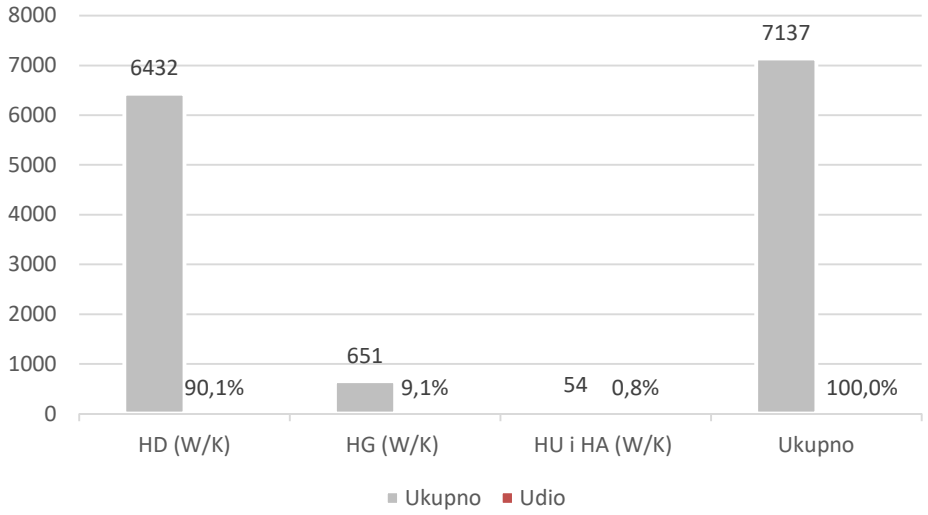

Slika 4.15 Prosječne vrijednosti i udio (%) koeficijenta transmisijske izmjene topline H_D (W/K), H_G (W/K) i zajednički H_U (W/K) i H_A (W/K) školskih zgrada u FBiH iz uzorka

Pravilnik o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije kao i ostali pravilnici u BiH i zemljama okruženja definiraju dopuštene vrijednosti koeficijenta transmisijske izmjene topline po jedinici površine ovojnice (A) grijanog dijela zgrade s oznakom $H'_{tr,adj}$ (W/m^{2}K) u odnosu na faktor kompaktnosti zgrade (f_o) i srednju mjesečnu temperaturu najhladnijeg mjeseca u godini ($\Theta_{e,mj}$). Stoga su izračunate vrijednosti $H'_{tr,adj}$ prema sljedećem izrazu [78]:

$$H'_{tr,adj} = \frac{H_{tr}}{A}\left[W / m^2 K\right] \tag{4.11}$$

gdje su:

- H_{tr} koeficijent transmisijske izmjene topline (W/K)
- A površina ovojnice zgrade (m^2).

Osim transmisijskih gubitaka analizirani se i ventilacijski gubitci H_{ve} koji nastaju kao posljedica infiltracije zraka i prirodne ventilacije uslijed otvaranja prozora i vrata. Prilikom izrade detaljnih pregleda nisu izvršena mjerenja zrakopropusnosti zgrade (tzv. Blower door test) pa su kod određivanja ventilacijskih gubitaka usvajane iskustvene vrijednosti broja izmjena zraka (h^{-1}).

U infiltraciji zraka najznačajniji udio imaju fasadni otvori (prozori i vrata) pa je infiltracija procijenjena na 1,2 h^{-1}, a promatrajući prirodnu ventilaciju otvaranjem prozora i vrata najznačajniju ulogu ima otvaranje vrata u svrhu komunikacije pa se pretpostavlja da vrijednost izmjene zraka uslijed manipulacije otvorima iznosi 0,8 h^{-1} [97].

Za školske zgrade u FBiH iz uzorka vrijednosti broja izmjena zraka kretale su se u vrijednostima od 1,0 h^{-1} do 2,5 h^{-1} ovisno o stanju otvora i ovojnice (fasade), te su određene vrijednosti koeficijenta ventilacijske izmjene topline po jedinici površine ovojnice grijanog dijela zgrade s oznakom H'_{ve} (W/m^2K).

Na temelju poznatih vrijednosti koeficijenta transmisijske izmjene topline $H'_{tr,adj}$ i koeficijenta ventilacijske izmjene topline H'_{ve} izračunat je ukupni koeficijent izmjene topline po jedinici površine ovojnice grijanog dijela zgrade s oznakom H' (W/m^2K) prema slijedećem izrazu:

$$H' = H'_{tr,adj} + H'_{ve} \left[W / m^2 K \right] \tag{4.12}$$

gdje su:

- H'_{tr} koeficijent transmisijske izmjene topline (W/m^2K)
- H'_{ve} koeficijent ventilacijske izmjene topline (W/m^2K).

Ukupni koeficijent izmjene topline po jedinici površine ovojnice grijanog dijela zgrade H' (W/m^2K) koristit će se kao jedan od parametara ili varijabli u istraživanju korelacija s potrošnjom toplinske energije. U tablici 4.9 prikazani su rezultati deskriptivne statistike za koeficijent transmisijske izmjene topline $H'_{tr,adj}$ (W/m^2K) i ukupni koeficijent izmjene topline H' (W/m^2K), a na slici 4.16 prikazani su histogrami broja školskih zgrada u FBiH iz uzorka.

Tablica 4.9 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema vrijednostima koeficijenta transmisijske izmjene topline $H'_{tr,adj}$ (W/m²K) i ukupnog koeficijenta izmjene topline H' (W/m²K)

Varijabla	n	x_{min}	x_{max}	R_x	$\bar{X}$	M_e	σ_x	V	q_1	q_3	V_q
Koeficijent H'_{tr} (W/m²K)	185	0,44	2,90	2,46	1,58	1,57	0,41	26,0%	1,28	1,86	18,3%
Koeficijent H' (W/m²K)	185	1,08	4,45	3,37	2,50	2,47	0,50	20,2%	2,18	2,80	12,5%

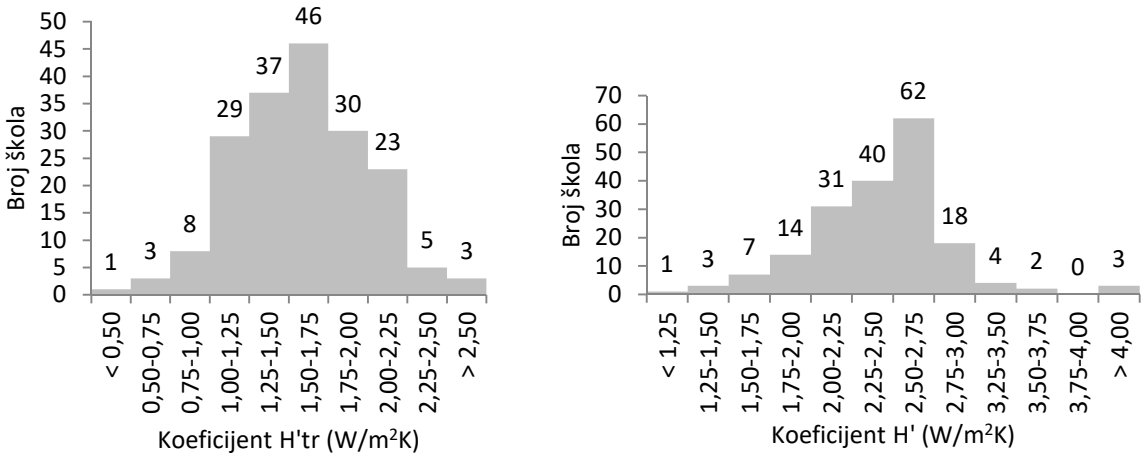

Slika 4.16 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na koeficijente transmisijske i ukupne izmjene topline $H'_{tr,adj}$ (W/m²K) i H' (W/m²K)

Analizirajući sliku 4.16 i tablicu 4.9 sa stajališta koeficijenata transmisijske i ukupne izmjene topline $H'_{tr,adj}$ i H' školskih zgrada u FBiH iz uzorka može se uočiti slaba disperzija (koeficijent varijacije iznosi do 30%). Koeficijent transmisijske izmjene topline $H'_{tr,adj}$ ima prosječnu vrijednost od 1,58 W/m²K, u rasponu vrijednosti od 1,00 do 2,25 W/m²K nalazi se 165 školskih zgrada ili 89,2%, a u rasponu od 1,28 do 1,86 W/m²K nalazi se 50% školskih zgrada iz uzorka. Prosječna vrijednost ukupnog koeficijenta izmjene topline H' iznosi 2,50 W/m²K, u rasponu vrijednosti od 2,00 do 3,00 W/m²K nalazi se 151 školska zgrada ili 81,6%, a u rasponu od 2,18 do 2,80 W/m²K nalazi se 50% školskih zgrada u FBiH iz uzorka. U tablici 4.10 dan je sažeti prikaz i usporedba prosječnih stvarnih i dopuštenih vrijednosti koeficijenta transmisijske izmjene topline.

Tablica 4.10 Podatci o prosječnim vrijednostima koeficijenta transmisijske izmjene topline $H'_{tr,adj}$, koeficijenta ventilacijske izmjene topline H'_{ve}, ukupnog koeficijenta izmjene topline H' i dopuštenih vrijednosti koeficijenta transmisijske izmjene topline $H'_{tr,adj,dop}$ (W/m²K) školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije

ŠKOLSKE ZGRADE U FBIH IZ UZORKA		Prosječni koeficijent transmisijske izmjene topline $H'_{tr,adj}$ (W/m²K)	Prosječni koeficijent ventilacijske izmjene topline H'_{ve} (W/m²K)	Ukupan prosječni koeficijent izmjene topline $H'=H'_{tr,adj}+H'_{ve}$ (W/m²K)	Prosječna dopuštena vrijednost koeficijenta transmisijske izmjene topline $H'_{tr,adj,dop}$ (W/m²K)	Prosječni odnos stvarne i dopuštene vrijednosti koeficijenta transmisijske izmjene topline
do 1945	FBiH	1,67	0,95	2,62	0,62	2,78
	RS FBiH	1,66	0,98	2,64	0,57	2,94
	RJ FBiH	1,70	0,87	2,57	0,72	2,38
od 1946 do 1965	FBiH	1,70	1,01	2,71	0,71	2,43
	RS FBiH	1,63	1,04	2,67	0,67	2,46
	RJ FBiH	1,93	0,90	2,83	0,84	2,35
od 1966 do 1973	FBiH	1,61	0,89	2,50	0,71	2,33
	RS FBiH	1,60	0,91	2,51	0,70	2,35
	RJ FBiH	1,67	0,81	2,48	0,75	2,29
od 1974 do 1987	FBiH	1,50	0,89	2,39	0,75	2,14
	RS FBiH	1,50	0,90	2,40	0,71	2,21
	RJ FBiH	1,52	0,83	2,35	0,85	1,89
od 1988 do 2009	FBiH	1,20	0,86	2,06	0,81	1,58
	RS FBiH	1,24	1,00	2,24	0,85	1,51
	RJ FBiH	1,16	0,71	1,87	0,77	1,64
od 2010	FBiH	0,44	0,64	1,08	0,83	0,53
	RS FBiH	-	-	-	-	-
	RJ FBiH	0,44	0,64	1,08	0,83	0,53
UKUPNO	FBiH	1,58	0,92	2,50	0,72	2,28
	RS FBiH	1,56	0,95	2,51	0,69	2,34
	RJ FBiH	1,62	0,84	2,46	0,81	2,08

Koeficijent transmisijske izmjene topline $H'_{tr,adj}$ uz U – vrijednosti predstavlja pokazatelj energetskih karakteristika ukupne ovojnice zgrade. Stvarne vrijednosti koeficijenta transmisijske izmjene topline u ukupnom uzorku približno su 2,3 puta veće od dopuštenih vrijednosti što ukazuje na jako loše toplinske karakteristike sadašnjeg stanja ovojnice školskih zgrada u FBiH iz uzorka.

4.3 Analiza potrošnje energije školskih zgrada u FBiH iz uzorka

4.3.1 Analiza stvarne potrošnje toplinske i električne energije školskih zgrada u FBiH iz uzorka

Kako je opisano u poglavlju 1.2 energetske karakteristike zgrade mogu se odrediti i usporedbom stvarne (izmjerene) i proračunske potrošnje energije. U ovom poglavlju izvršena je analiza postojeće (stvarne) potrošnje toplinske i električne energije (budući da dokumenti DEA raspolažu i s podatcima o potrošnji električne energije) kako bi se utvrdio stupanj potrošnje i odnos potrošnje toplinske i električne energije. Prikupljene su prosječne godišnje vrijednosti (vrijednosti potrošnje na temelju prethodne 3 godine u odnosu na godinu izrade DEA) isporučene toplinske energije za grijanje i električnu energiju školskih zgrada u FBiH iz uzorka.

Stvarna potrošnja toplinske energije osim karakteristika zgrade i njenih građevinskih dijelova ovojnice i opreme prema istraživanjima ovisi i o načinu ponašanja korisnika koja može imati značajan utjecaj na potrošnju energije [16] što ovim istraživanjem nije obuhvaćeno.

Potrošnja toplinske energije za grijanje i električne energije mjeri se kroz isporučenu energiju. Isporučena energija je energija izražena po nositelju energije, koja se dovodi u tehnički sustav u zgradu kroz granicu sustava kako bi se zadovoljile potrebe za grijanjem, hlađenjem, ventilacijom, potrošnom toplom vodom, rasvjetom, uređajima itd. [81].

Isporučena godišnja toplinska energije za grijanje ($Q_{H,del}$) prema standardu BAS EN ISO 13790:2008 predstavlja energiju koja se doprema u tehničke sustave zgrade kako bi se zadovoljile potrebe za grijanjem. Isporučena energija može se izračunati ili mjeriti [98]. Godišnja isporučena električna energija (E_{del}) predstavlja količinu električne energije koju treba dovesti zgradi tijekom jedne godine za potrebe rasvjete, rada aparata i uređaja koji troše električnu energiju. Prema Pravilniku [81] proračunava se samo godišnja potrebna energija za rasvjetu (E_L) ali u ovom istraživanju razmatra se ukupna godišnja potrošnja električne energije (E_{del}).

Osim ukupne godišnje isporučene godišnje toplinske energije za grijanje ($Q_{H,del}$) određena je i specifična stvarna isporučena godišnja toplinska energija za grijanje ($Q'_{H,del}$)u odnosu na korisnu površinu zgrade (A_k) prema sljedećem izrazu:

$$Q'_{H,del} = \frac{Q_{H,del}}{A_k}\left[kWh/m^2 god\right] \tag{4.13}$$

Specifična stvarna isporučena električna energija (E'_{del}) određena je u odnosu na korisnu površinu zgrade (A_k) prema sljedećem izrazu:

$$E'_{del} = \frac{E_{del}}{A_k}\left[kWh/m^2god\right] \tag{4.14}$$

Specifične vrijednosti potrošnje toplinske i električne energije bolji su pokazatelji ili indikatori u odnosu na ukupne vrijednosti potrošnje energije jer se ista izražava u odnosu na korisnu površinu zgrade (A_k) što omogućava usporedbu istih. U tablici 4.11 i slici 4.17 prikazani su rezultati deskriptivne statistike za stvarnu specifičnu isporučenu toplinsku energiju za grijanje ($Q'_{H,del}$) i stvarnu specifičnu električnu energiju (E'_{del}) školskih zgrada u FBiH iz uzorka.

Tablica 4.11 Podatci deskriptivne statistike prema stvarnoj specifičnoj isporučenoj toplinskoj energiji za grijanje ($Q'_{H,del}$) i specifičnoj električnoj energiji (E'_{del}) školskih zgrada u FBiH iz uzorka

Varijabla	n	x_{min}	x_{max}	R_x	$\bar{X}$	M_e	σ_x	V	q_1	q_3	V_q
$Q'_{h,del}$ (kWh/m²god)	185	13,66	397,75	384,08	145,59	131,25	82,80	56,9%	81,53	193,26	40,7%
E'_{del} (kWh/m²god)	184	0,75	35,71	34,96	11,32	10,39	5,91	52,2%	7,54	13,74	29,1%

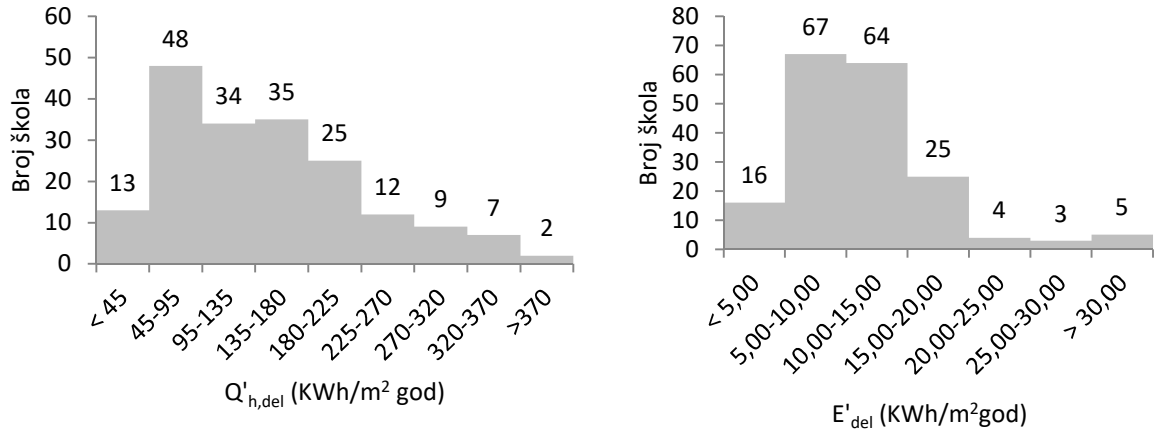

Slika 4.17 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na specifičnu isporučenu toplinsku energiju za grijanje ($Q'_{H,del}$) i specifičnu isporučenu električnu energiju (E'_{del})

Koeficijenti varijacije (V) za specifičnu isporučenu toplinsku energiju za grijanje ($Q'_{H,del}$) i specifičnu isporučenu električnu energiju (E'_{del}) imaju jaku varijaciju (preko 50%) što upućuje na nejednoliku razdiobu.

Prosječna vrijednost specifične isporučene toplinske energije za grijanje ($Q'_{H,del}$) iznosi 145,59 kWh/m^{2}god, u rasponu vrijednosti od 81,50 do 193,30 kWh/m^{2}god nalazi se 50% školskih zgrada u FBiH iz uzorka. Prosječna vrijednost isporučenu električnu energiju (E'_{del}) iznosi 11,32 kWh/m^{2}god, u rasponu vrijednosti od 5,00 do 15,00 kWh/m^{2}god nalazi se 131 ili 70,8%, a u rasponu od 7,50 do 13,50 W/m^{2}K nalazi se 50% školskih zgrada u FBiH iz uzorka.

Koeficijent kvartilne devijacije (V_q) (relativna mjera disperzije središnjih 50% podataka skupa) za specifičnu isporučenu toplinsku energiju za grijanje ($Q'_{H,del}$) iznosi preko 40% što predstavlja relativno jak varijabilitet. Zbog navedenog je urađena deskriptivna statistika (čiji su rezultati prikazani u tablici 4.12 i slici 4.18) posebno za školske zgrade iz regije sjever (RS) i regije jug (RJ) FBiH kako bi se istražio utjecaj klimatskih uvjeta na razdiobu podataka.

Tablica 4.12 Podatci deskriptivne statistike prema stvarnoj specifičnoj isporučenoj toplinskoj energiji za grijanje ($Q'_{H,del}$)školskih zgrada u FBiH iz uzorka prema klimatskim regijama RS i RJ FBiH

Varijabla	n	x_{min}	x_{max}	R_x	$\bar{X}$	M_e	σ_x	V	q_1	q_3	V_q
$Q'_{h,del}$ RS FBiH (kWh/m^{2}god)	138	34,84	397,75	362,91	166,20	154,27	77,75	46,8%	106,31	209,77	32,7%
$Q'_{h,del}$ RJ FBiH (kWh/m^{2}god)	47	13,66	366,03	352,37	85,08	65,34	65,77	77,3%	48,77	98,19	33,6%

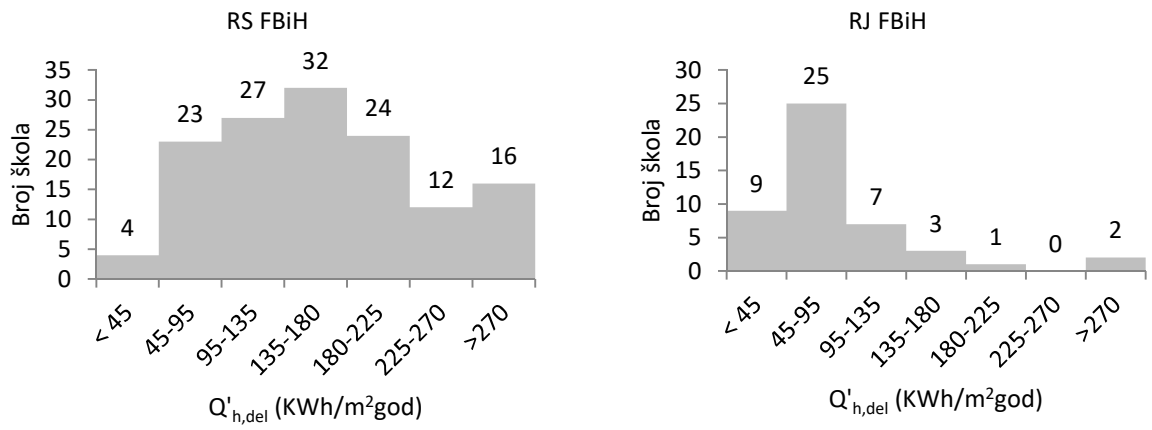

Slika 4.18 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na specifičnu isporučenu toplinsku energiju za grijanje ($Q'_{H,del}$) u RS i RJ FBiH

Koeficijenti varijacije (V) za specifičnu isporučenu toplinsku energiju za grijanje ($Q'_{H,del}$) u RS i RJ FBiH imaju umjerenu do jaku varijaciju. Navedeno upućuje da potrošnja toplinske energije ne ovisi samo o energetskim karakteristikama školskih zgrada nego i o drugim faktorima kao što su raspoloživa

novčana sredstva isl. Prosječna vrijednost specifične isporučene toplinske energije za grijanje ($Q'_{H,del}$) u RS FBiH iznosi 166,20 kWh/m^{2}god, a u RJ FBiH iznosi 85,08 kWh/m^{2}god.

U tablici 4.13 dan je sažeti prikaz prosječnih vrijednosti stvarne specifične potrošnje isporučene toplinske energije za grijanje ($Q'_{H,del}$), specifične potrošnje električne energije (E'_{del}), ukupne specifične potrošnje toplinske i električne energije te udjela u ukupnoj potrošnji. Navedeno je prikazano za ukupan uzorak školskih zgrada u FBiH u odnosu na razdoblje izgradnje i klimatske regije.

Tablica 4.13 Podatci o prosječnim vrijednostima stvarne specifične potrošnje isporučene toplinske energije za grijanje ($Q'_{H,del}$), specifične potrošnje električne energije (E'_{del}), ukupne specifične potrošnje toplinske i električne energije te udjeli u ukupnoj potrošnji školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije

ŠKOLSKE ZGRADE U FBIH IZ UZORKA		Prosječna stvarna specifična isporučena toplinska energija za grijanje $Q'_{h,del}$ (kWh/m^{2}god)	Prosječna stvarna specifična potrošnja električne energije (E'_{del}) (kWh/m^2 god)	Ukupna specifična potrošnja isporučene toplinske energije za grijanje i električne energije (kWh/m^{2}god)	Udio isporučene toplinske energije za grijanje u ukupnoj potrošnji (%)	Udio električne energije u ukupnoj potrošnji (%)
do 1945	FBiH	148,81	13,87	162,68	91,5%	8,5%
	RS FBiH	177,38	14,30	191,68	92,5%	7,5%
	RJ FBiH	77,40	12,77	90,17	85,8%	14,2%
od 1946 do 1965	FBiH	142,15	10,51	152,66	93,1%	6,9%
	RS FBiH	159,97	10,23	170,20	94,0%	6,0%
	RJ FBiH	87,30	11,39	98,69	88,5%	11,5%
od 1966 do 1973	FBiH	158,72	10,76	169,48	93,7%	6,3%
	RS FBiH	170,01	10,90	180,91	94,0%	6,0%
	RJ FBiH	119,21	10,26	129,47	92,1%	7,9%
od 1974 do 1987	FBiH	150,77	11,31	162,08	93,0%	7,0%
	RS FBiH	172,06	11,27	183,33	93,9%	6,1%
	RJ FBiH	80,61	11,43	92,04	87,6%	12,4%
od 1988 do 2009	FBiH	72,67	13,85	86,52	84,0%	16,0%
	RS FBiH	91,86	15,39	107,25	85,7%	14,3%
	RJ FBiH	53,47	12,32	65,79	81,3%	18,7%
od 2010	FBiH	16,13	8,16	24,29	66,4%	33,6%
	RS FBiH	-	-	-	-	-
	RJ FBiH	16,13	8,16	24,29	66,4%	33,6%
UKUPNO	FBiH	145,59	11,26	156,85	92,8%	7,2%
	RS FBiH	166,20	11,23	177,43	93,7%	6,3%
	RJ FBiH	85,08	11,34	96,42	88,2%	11,8%

Analizirajući tablicu 4.13 s prosječnim vrijednostima potrošnje toplinske i električne energije može se zaključiti da je udio potrošnje toplinske energije dominantan i na razini ukupnog uzorka iznosi oko 93% a za električnu energiju udio iznosi oko 7%.

U klimatskoj regiji jug FBiH udio potrošnje toplinske energije školskih zgrada iz uzorka iznosi oko 88% a za električnu energiju udio iznosi oko 12% što je posljedica činjenice da se jedan dio škola u prijelaznim razdobljima grije na električnu energiju koristeći klima uređaje.

4.3.2 Analiza proračunske potrošnje toplinske energije školskih zgrada u FBiH iz uzorka

Potrebno je utvrditi odgovara li stvarna potrošnja toplinske energije i u kojoj mjeri potrebama za predviđenu namjenu zgrade zbog čega se vrši proračun ili modeliranje toplinske energije sukladno važećim propisima ili standardima. U dokumentima detaljnih energetskih pregleda (DEA) vrši se proračun potrebne toplinske energije kojom se utvrđuju stvarne potrebe.

U izradi modela kojim se predviđa ili procjenjuje (proračunava) potrošnja toplinske energije tijekom posljednjih nekoliko godina predloženi su i primijenjeni različiti pristupi odozdo prema gore (*bottom-up*) i odozgo prema dolje (*top-down*) ovisno o raspoloživim podatcima. Takvi modeli zahtijevaju određeni stupanj uopćavanja, što posljedično ostavlja prostor za neizvjesnost i nosi rizik od potencijalne pogrešne interpretacije [30]:

- pristup odozdo prema gore (*bottom-up*) nastoje prikupiti informacije od ''visoko reprezentativnih“ uzoraka što omogućuje usporedbu i prilagođavanje stvarne potrošnje energije i izračunate potrošnje energije (određena pomoću statičkih ili dinamičkih alata za izračunavanje, računajući podatke o toplinskoj ovojnici zgrade). Na temelju malog broja uzoraka zgrada uspostavljaju se sustavi klasifikacije koji omogućavaju svrstavanje velikog broja zgrada u razrede i, nakon toga, u tipične razine potrošnje energije. Široko se koriste tipologija i klasifikacijski sustavi zgrada, razlikujući se prema različitim razdobljima izgradnje i namjene zgrade. Ovi se klasifikacijski sustavi oslanjaju na pretpostavku da će, dodjeljujući zgradu određenoj dobnoj klasi ili razdoblju izgradnje, naslijediti energetski značajne karakteristike klase. Dodatni aspekti, poput U-vrijednosti toplinske ovojnice, automatski se uzimaju u obzir.
- pristup odozgo prema dolje (*top-down*) zanemaruje uobičajeno uzete u obzir karakteristike zgrade, poput razdoblja izgradnje, tipa ili U-vrijednosti toplinske ovojnice. Ovi modeli predviđaju potrošnju energije zgrade isključivo prema njezinoj namjeni (funkciji) i površini.

Pristup odozdo prema gore temelji se na velikoj bazi podataka o potrošnji energije te na detaljnim geometrijskim informacijama o pojedinim zgradama. Analiza postojećih karakteristika zgrada i podatci

o stvarnoj potrošnji energije olakšavaju izradu modela procjene potrošnje energije [30]. Također, u procjeni i modeliranju energetske učinkovitosti zgrada koriste se različiti oblici i modeli ovisno o raspoloživim podatcima [99]:

- modeli crne kutije koji statistički koriste malo podataka potrebnih za svaku zgradu. Koriste se jednostavni matematički ili statistički modeli koji na temelju utjecajnih ulaznih parametara predviđaju energetske karakteristike zgrada,
- modeli bijele kutije, opisani kao inženjerski pristup, temelje se na građevinskoj fizici i uvelike ovise o korisničkim ulaznim podatcima,
- modeli sive kutije, koji se nazivaju i hibridni pristup, koriste određene ključne parametre sustava identificirane iz modela fizičkog sustava i kombiniraju ograničenu građevinsku fiziku sa statističkim metodologijama i
- detaljan pristup kalibraciji modela koristi potpuno opisan model građevinskog sustava i podešava različite ulaze kako bi odgovarao izmjerenim podatcima. Ovaj pristup daje najdetaljnije predviđanje energetskih karakteristika zgrade, s obzirom na dostupnost kvalitetnih ulaznih podataka.

Jedan od pristupa za ocjenu energetskih karakteristika zgrade jeste korištenje podataka o zgradi za izračunavanje razine potrošnje energije odozdo prema gore, proračunavajući potrebnu energiju, koja bi se zatim mogla usporediti sa stvarnom potrošnjom energije [31]. S obzirom na navedeno i veliki broj raspoloživih podataka iz DEA o poznatim toplinskim karakteristikama građevinskih dijelova ovojnice za svaku zgradu iz uzorka i izračunatih koeficijenata transmisijske izmjene topline i ventilacijske izmjene topline, u modeliranju i proračunu toplinske energije za grijanje za postojeće stanje koristi se pristup odozdo prema gore i inženjerske metode temeljene na modeliranju i analizi pomoću fizikalnih zakona i matematičkih formula.

Međunarodna norma ISO 16346 definira procese za metodologije proračuna, koristeći metodu izračuna prema ISO 13790 kao osnovu za izračunavanje potrebne energije za grijanjem i hlađenjem [31]. Potrebna toplinska energija za grijanje ($Q_{H,nd}$) predstavlja računski određenu količinu topline koju sustavom grijanja treba tijekom jedne godine dovesti u zgradu za održavanje unutrašnje projektne temperature u zgradi tijekom razdoblja grijanja zgrade. Potrebna energija se izračunava i ne može se lako izmjeriti [81, 98]. Godišnja potrebna toplinska energija za grijanje zgrade ($Q_{H,nd}$) (kWh/god) proračunava se u skladu s normom BAS EN ISO 13790, metoda proračuna po mjesecima [78].

Proračun toplinske energije ide s lijeva na desno (slika 4.19). Prvo se proračunava potrebna energija za grijanje (korisna energija) koju treba dovesti prostoru koji se grije da bi se održala željena temperatura u zadanom vremenskom razdoblju. Godišnja potrebna toplinska energija za grijanje ($Q_{H,nd}$) proračunava se u skladu s normom BAS EN ISO 13790 prema slijedećem osnovnom izrazu [100]:

$$Q_{\mathrm{H,nd}} = Q_{\mathrm{H,ht}} - \eta_{\mathrm{H,gn}} \cdot Q_{\mathrm{H,gn}} = Q_{\mathrm{tr}} + Q_{\mathrm{ve}} - \eta_{\mathrm{H,gn}} \cdot (Q_{\mathrm{int}} + Q_{\mathrm{sol}}) \left[kWh / god \right] \tag{4.15}$$

gdje su:

- $Q_{\mathrm{H,ht}}$ ukupni gubitci toplinske energije u razdoblju grijanja (transmisijski, ventilacijski i infiltracijski) (kWh/god),
- $\eta_{\mathrm{H,gn}}$ faktor iskorištenja toplinskih dobitaka,
- $Q_{\mathrm{H,gn}}$ ukupni toplinski dobitci u zgradi u razdoblju grijanja (sunčano zračenje, ljudi, rasvjeta i ostali aparati) (kWh/god),
- Q_{tr} transmisijski gubitci toplinske energije u razdoblju grijanja (kWh/god),
- Q_{ve} ventilacijski i infiltracijski gubitci toplinske energije u razdoblju grijanja (kWh/god),
- Q_{int} toplinski dobitci u zgradi u razdoblju grijanja (ljudi, rasvjeta i ostali aparati) (kWh/god) i
- Q_{sol} toplinski dobitci od sunčeva zračenja (kWh/god).

Godišnja potrebna toplinska energija za grijanje ($Q_{H,nd}$) proračunava se na temelju poznatih ulaznih podataka iz dokumenata detaljnih energetskih pregleda (DEA) za svaku zgradu (podatci kao što su lokacija sa srednjim mjesečnim temperaturama zraka, korisna površina (A_k), površina ovojnice (A), zapremina grijanog dijela zgrade (V_e), neto zapremina grijanog zraka (V), faktor kompaktnosti zgrade (f_o), koeficijent transmisijske izmjene topline ($H_{tr,adj}$), koeficijent ventilacijske izmjene topline (H_{ve}),i proračunski parametri kao efektivni toplinski kapacitet C_m i faktor koji uzima u obzir prekida rada grijanja $\alpha_{H,red}$). Za proračun potrebne toplinske energije za grijanje ($Q_{H,nd}$) prema normi BAS EN ISO 13790 postoji složeni algoritam i u ovom radu se ne će prikazivati.

U nastavku ovog rada godišnja proračunska ili modelirana potrebna toplinska energija za grijanje zgrade ($Q_{H,nd,cal}$) označena je s dodatnim indeksom "cal" (*calculated*) kako bi se ista razlikovala od stvarne ili dopuštene vrijednosti potrebne toplinske energije za grijanje ($Q_{H,nd}$).

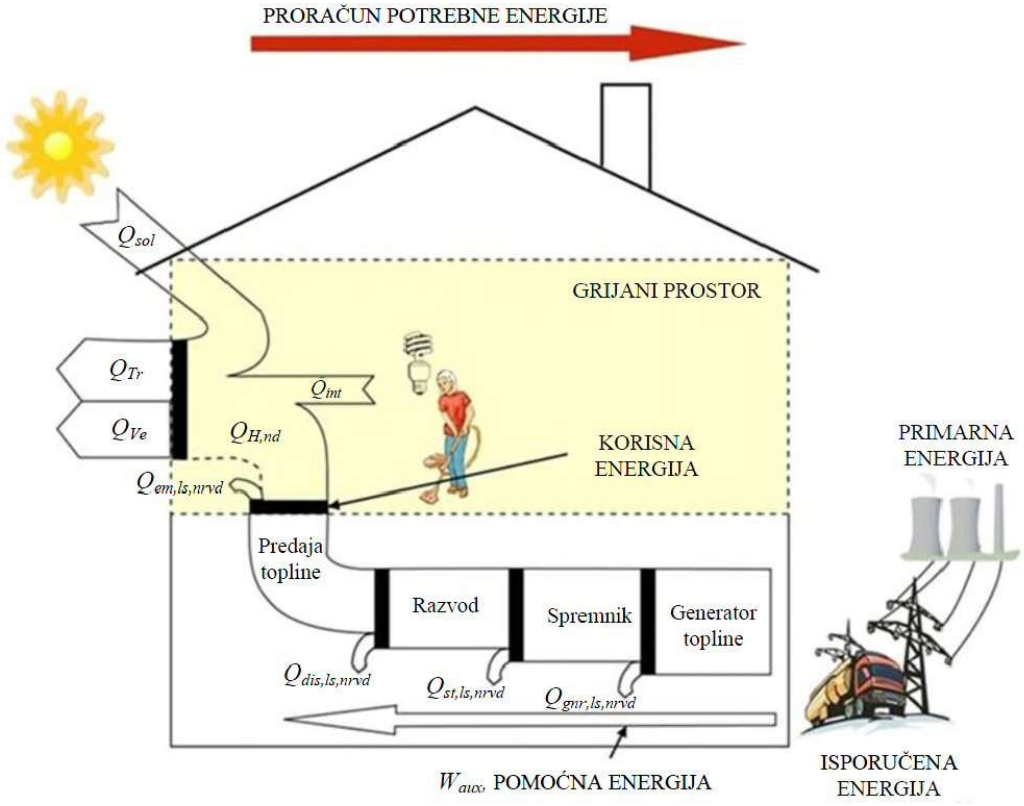

Slika 4.19 Shema proračuna potrebne toplinske energije [100]

Prikupljanjem podataka o proračunskoj godišnjoj potrebnoj toplinskoj energiji za grijanje ($Q_{H,nd,cal}$) iz DEA školskih zgrada u FBiH iz uzorka uočeno je kako su u modeliranju i proračunu proračunske potrebne toplinske energije za grijanje ($Q_{H,nd,cal}$) različiti izrađivači koristili različite proračunske parametre (režim rada, redukcijski faktori, nedefinirani ventilacijski gubitci). Kako bi rezultati proračuna godišnje potrebne toplinske energije za grijanje ($Q_{H,nd,cal}$) školskih zgrada u FBiH iz uzorka za postojeće stanje istih bili usporedivi napravljen je model proračuna sukladno standardu BAS EN ISO 13790, te je na temelju poznatih ulaznih podataka za svaku školsku zgradu izvršen proračun potrebne toplinske energije za grijanje ($Q_{H,nd,cal}$).

Unutarnja projektirana temperatura za školske zgrade iznosi Θ_{int}= 20°C. Klimatski uvjeti definirani su srednjim mjesečnim temperaturama ovisno o lokaciji zgrade i značajno utječu na trajanje sezone grijanja, a time i na ukupnu godišnju proračunsku potrebnu ($Q_{H,nd,cal}$) toplinsku energiju za grijanje.

Podatci iz DEA pokazuju da za školske zgrade smještene u klimatskoj regiji ''sjever'' FBiH sezona grijanja prosječno traje 7 mjeseci (listopad, studeni, prosinac, siječanj, veljača, ožujak i travanj) a u regiji ''jug'' prosječno traje 5 mjeseci (studeni, prosinac, siječanj, veljača i ožujak). Također, prema podatcima iz DEA o režimu rada sustava grijanja prosječan broj sati rada dnevno u klimatskoj regiji ''sjever'' FBiH iznosi oko 11,5 h, dok u regiji ''jug'' iznosi oko 9,5 h.

Specifična proračunska potrebna godišnja toplinska energija za grijanje ($Q'_{H,nd,cal}$) određuje se u odnosu na korisnu površinu grijanog dijela zgrade(A_k) prema sljedećem izrazu [78]:

$$Q'_{H,nd,cal} = \frac{Q_{H,nd,cal}}{A_k}\left[kWh/m^2 god\right] \tag{4.16}$$

Pravilnik o tehničkim zahtjevima za toplinsku zaštitu zgrada i racionalnu uporabu energije za nestambene zgrade definira dopuštenu vrijednost potrebne godišnje toplinske energije za grijanje ($Q''_{H,nd}$) po jedinici zapremine grijanog dijela zgrade (V_e) prema sljedećem izrazu [78]:

$$Q''_{H,nd} = \frac{Q_{H,nd}}{V_e}\left[kWh/m^3 god\right] \tag{4.17}$$

Prosječna proračunska potrebna toplinska energija za grijanje ($Q''_{H,nd,cal}$) za ukupan uzorak iznosi 43,42 kWh/m^{3}god a prosječna dopuštena potrebna toplinska energija za grijanje iznosi 22,26 kWh/m^{3}god. Usporedbom prosječnih vrijednosti proračunske i dopuštene potrebe toplinske energije za grijanje ($Q''_{H,nd}$) može se vidjeti kako je stvarna približno dva puta veća od dopuštene. Razlozi ovome dvostrukom povećanju su objašnjeni već u prethodnim poglavljima rada u kojima je zaključeno kako ovojnica ima jako loše toplinske karakteristike.

Prema Pravilniku o energetskom certificiranju zgrada vrijednosti specifične potrebne godišnje toplinske energije za grijanje ($Q'_{H,nd}$) u postupku energetskog certificiranja određuju se prema referentnim klimatskim podatcima na temelju čega se određuje energetski razred zgrade (energetski razredi grafički su prikazani na slici 4.20) izraženi u kWh/m^{2}god [79].

Za ovo istraživanje određeni su približni energetski razredi školskih zgrada u FBiH iz uzorka u odnosu na stvarne klimatske uvjete i prema proračunskoj specifičnoj potrebnoj godišnjoj toplinskoj energiji za grijanje ($Q'_{H,nd,cal}$) (kWh/m^{2}god) jer nije izvršeno energetsko certificiranje koje se provodi u odnosu na referentne klimatske uvjete (postupak energetskog certificiranja i određivanja energetskog razreda

zahtijeva novi proračun potrebne toplinske energije prema referentnim klimatskim uvjetima što ovo istraživanje nije uključivalo).

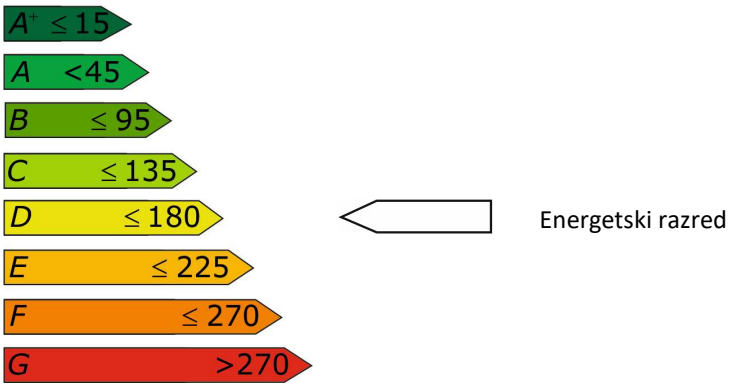

Slika 4.20 Vrijednosti i energetski razredi u FBiH [79]

Zatim slijedi proračun isporučene toplinske energije ($Q_{H,del,cal}$) (dodan je indeks "cal" kao i kod proračunske potrebne toplinske energije) uzimajući u obzir iskoristive i neiskoristive gubitke termotehničkih sustava ili pojednostavljeno uzimajući u obzir toplinske gubitke sustava kroz stupanj učinkovitosti sustava. Proračunska godišnja isporučena toplinska energija za grijanje ($Q_{H,del,cal}$) (energija koju je potrebno proizvesti iz korištenog energenta uz postojeći stupanj učinkovitosti sustava grijanja kako bi se osigurali toplinski uvjeti u prostoru) uspoređuje se sa stvarnom potrošnjom isporučene energije $Q_{H,del}$ na temelju čega se utvrđuje zadovoljava li stvarna potrošnja trenutne potrebe.

Proračunska godišnja isporučena toplinska energija za grijanje ($Q_{H,del,cal}$) predstavlja količnik proračunske godišnje potrebne toplinske energije za grijanje ($Q_{H,nd,cal}$) i ukupnog stupnja učinkovitosti sustava grijanja (η_{sys}) prema sljedećem izrazu [100]:

$$Q_{\mathrm{H,del,cal}} = \frac{Q_{\mathrm{H,nd}}}{\eta_{\mathrm{sys}}} \left[kWh / god \right] \tag{4.18}$$

gdje je:

- η_{sys} ukupan stupanj ili koeficijent učinkovitosti sustava grijanja uključujući proizvodnju, elektroniku, transport, spremanje, distribuciju osim ukoliko je naznačeno bez godišnje potrebne energije za pogon pomoćnih sustava.

Ukupan stupanj učinkovitosti sustava grijanja (η_{sys}) predstavlja korisnost pretvorbe isporučene ($Q_{H,del}$) u potrebnu ($Q_{H,nd}$) toplinsku energiju i ovisi o stanju sustava grijanja i njegovih elemenata (kotla, razvoda i regulacije). Na temelju podataka iz DEA za školske zgrade u FBiH iz uzorka prosječna vrijednost stupnja učinkovitosti sustava grijanja iznosi η_{sys} =0,73 ili približno 73 %, što znači da prosječno 27% gubitaka isporučene toplinske energije nastaje u sustavu grijanja. Zbog navedenog u mjerama za poboljšanje predviđaju se i termotehničke mjere na poboljšanju sustava grijanja kako bi se smanjili gore navedeni gubitci.

Specifična proračunska isporučena godišnja toplinska energija za grijanje ($Q'_{H,del,cal}$) određena je u odnosu na korisnu površinu zgrade (A_k) prema sljedećem izrazu:

$$Q'_{H,del,cal} = \frac{Q_{H,del,cal}}{A_k}\left[kWh/m^2 god\right] \tag{4.19}$$

U tablici 4.14 i slici 4.21 prikazani su rezultati statističke analize proračunske specifične potrebne godišnje toplinske energije ($Q'_{H,nd,cal}$) i proračunske specifične godišnje isporučene toplinske energije ($Q'_{H,del,cal}$) za grijanje.

Tablica 4.14 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema vrijednostima proračunske specifične potrebne godišnje toplinske energije za grijanje ($Q'_{H,nd,cal}$) i proračunske specifične godišnje isporučene toplinske energije ($Q'_{H,del,cal}$)

Varijabla	n	x_{min}	x_{max}	R_x	$\bar{X}$	M_e	σ_x	V	q_1	q_3	V_q
$Q'_{h,nd,cal}$ (KWh/m²god)	185	27,59	420,80	393,21	171,90	169,29	74,23	43,2%	120,24	211,92	27,6%
$Q'_{h,del}$ (KWh/m²god)	185	32,09	788,23	756,15	242,91	226,77	123,21	50,7%	155,33	303,92	32,4%

Analizirajući tablicu 4.14 može se uočiti umjerena disperzija (koeficijent varijacije iznosi od 30% do 50%). Specifična proračunska potrebna godišnja toplinska energija za grijanje ($Q'_{H,nd,cal}$) ima prosječnu vrijednost od 171,90 kWh/m²god; u rasponu vrijednosti od 45,00 do 225,00 kWh/m²god nalazi se 148 školskih zgrada ili 80,0%, a u rasponu od oko 120,00 do 212,00 kWh/m²god nalazi se 50% školskih zgrada u FBiH iz uzorka.

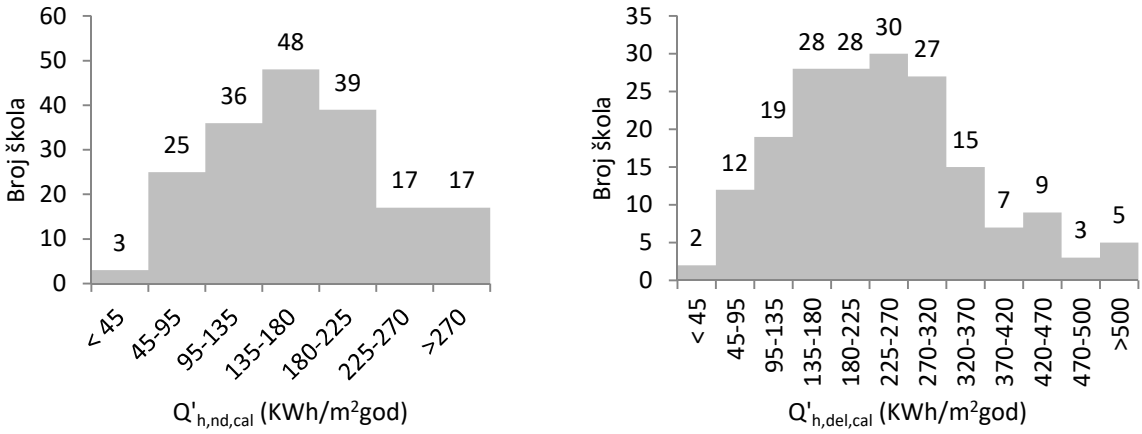

Slika 4.21 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na proračunsku specifičnu potrebnu ($Q'_{H,nd,cal}$) i proračunsku isporučenu godišnju toplinsku energiju ($Q'_{H,del,cal}$) za grijanje

Razredi specifične proračunske potrebne godišnje toplinske energije za grijanje ($Q'_{H,nd,cal}$) na slici 4.21 definirani su i usklađeni prema vrijednostima i razredima Pravilnika o energetskom certificiranju zgrada, a razredi specifične isporučene godišnje toplinske energije za grijanje ($Q'_{H,del,cal}$) su prošireni u odnosu na gornji razred od 270,00 kWh/m^{2}god.

Prosječna vrijednost proračunske specifične isporučene ($Q'_{H,del,cal}$) godišnje toplinske energije za grijanje iznosi 242,91 kWh/m^{2}god, u rasponu vrijednosti od 95,00 do 320,00 kWh/m^{2}god nalazi se 132 školske zgrade ili 71,4%, a u rasponu od oko 155,00 do 304,00 kWh/m^{2}god nalazi se 50% školskih zgrada u FBiH iz uzorka.

Sa stajališta klimatskih uvjeta, kao jednog od parametara koji imaju značajan utjecaj na potrošnju toplinske energije za grijanje, izvršena je posebna analiza proračunske potrebne godišnje toplinske energije za grijanje ($Q'_{H,nd,cal}$) školskih zgrada u FBiH iz uzorka u odnosu na klimatske regije ''sjever'' (RS) i ''jug'' (RJ) FBiH što je prikazano u tablici 4.15 i slici 4.22.

Tablica 4.15 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema vrijednostima proračunske specifične potrebne godišnje toplinske energije za grijanje ($Q'_{H,nd,cal}$) prema klimatskim regijama sjever (RS) i jug (RJ) u FBiH

Varijabla	n	x_{min}	x_{max}	R_x	$\bar{X}$	M_e	σ_x	V	q_1	q_3	V_q
$Q'_{h,nd,cal}$ RS FBiH (KWh/m^{2}god)	138	82,62	420,80	338,18	197,05	183,63	65,65	33,3%	149,97	224,73	19,9%
$Q'_{h,nd,cal}$ RJ FBiH (KWh/m^{2}god)	47	27,59	199,94	172,35	98,04	90,25	41,52	42,4%	68,31	120,57	27,7%

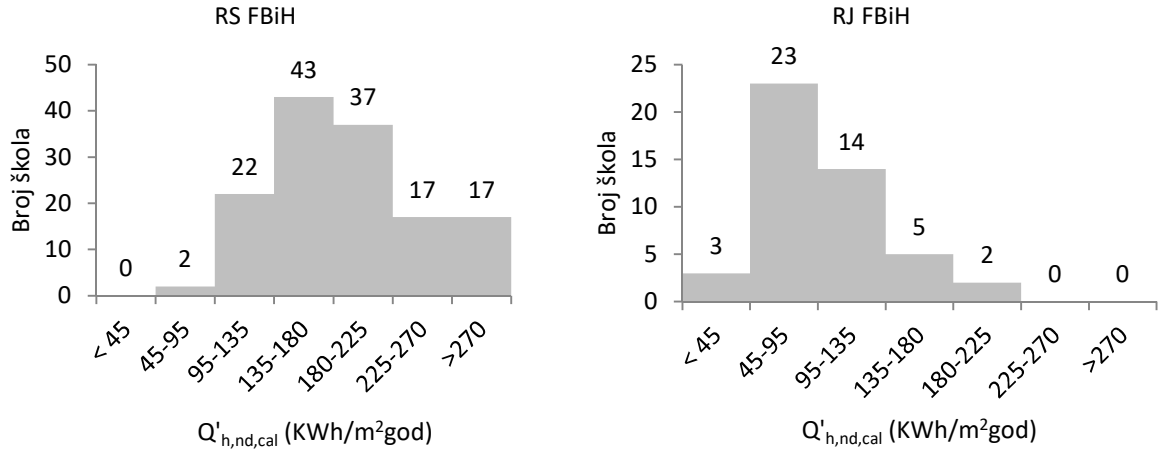

Slika 4.22 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na proračunsku specifičnu potrebnu godišnju toplinsku energiju za grijanje ($Q'_{H,nd,cal}$) prema klimatskim regijama u FBiH

Analizirajući podatke stajališta proračunske specifične potrebne godišnje toplinske energije za grijanje ($Q'_{H,nd,cal}$) školskih zgrada u FBiH iz uzorka po klimatskim regijama u FBiH iz uzorka može se uočiti umjerena disperzija. Vrijednosti energetskih razreda prema Pravilniku o energetskom certificiranju zgrada u FBiH nisu podijeljeni prema klimatskim regijama nego isti vrijede za cijelu FBiH. Prosječna vrijednost specifične potrebne godišnje toplinske energije za grijanje ($Q'_{H,nd,cal}$) u regiji sjever (RS) FBiH iznosi 197,05 kWh/m^{2}god (energetski razred E) i veća je od prosječne vrijednosti na razini cjelokupnog uzorka (171,90 kWh/m^{2}god) za oko 15%. U rasponu vrijednosti od 95,00 do 225,00 kWh/m^{2}god nalaze se 102 školske zgrade ili 73,9%, a u rasponu od oko 150,00 do 225,00 kWh/m^{2}god nalazi se 50% školskih zgrada iz uzorka regiji sjever FBiH.

Prosječna vrijednost proračunske specifične potrebne godišnje toplinske energije za grijanje ($Q'_{H,nd,cal}$) u regiji jug (RJ) FBiH iznosi 98,04 kWh/m^{2}god (energetski razred C) i manja je od prosječne vrijednosti na razini cjelokupnog uzorka (171,90 kWh/m^{2}god) za oko 43%. U rasponu vrijednosti od 45,00 do 135,00 kWh/m^{2}god nalazi se 37 školskih zgrada ili 78,7%, a u rasponu od oko 68,00 do 121,00 kWh/m^{2}god nalazi se 50% školskih zgrada iz uzorka regije jug.

Specifična proračunska potrebna godišnja toplinska energija za grijanje ($Q'_{H,nd,cal}$) u regiji sjever (RS) približno je dva puta veća u odnosu na regiju jug (RJ) FBiH. Može se zaključiti kako klimatski uvjeti i trajanje sezone grijanja imaju veliki utjecaj na potrebnu toplinsku energiju što posljedično utječe i isporučenu toplinsku energiju kao i na ukupne troškove grijanja.

U tablici 4.16 dan je sumaran prikaz prosječnih vrijednosti proračunske specifične godišnje potrebne toplinske energije za grijanje ($Q'_{H,nd,cal}$), energetski razred, proračunske i stvarne godišnje isporučene toplinske energije za grijanje ($Q'_{H,del}$), te usporedba stvarne i proračunske isporučene toplinske energije školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije.

Tablica 4.16 Podatci o prosječnim vrijednostima proračunske specifične godišnje potrebne toplinske energije za grijanje ($Q'_{H,nd,cal}$), energetskom razredu, proračunske godišnje isporučene toplinske energije za grijanje ($Q'_{H,del,cal}$) (kWh/m^{2}god), stvarne godišnje isporučene toplinske energije za grijanje ($Q'_{H,del}$) i prosječnog odnosa stvarne i proračunske vrijednosti isporučene toplinske energije školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije

ŠKOLSKE ZGRADE U FBIH IZ UZORKA		Prosječna proračunska specifična potrebna toplinska energija za grijanje $Q'_{h,nd,cal}$ (kWh/m^{2}god)	Energetski razred	Prosječna proračunska isporučena toplinska energija za grijanje $Q'_{h,del,cal}$ (kWh/m^{2}god)	Prosječna stvarna isporučena toplinska energija za grijanje $Q'_{h,del}$ (kWh/m^{2}god)	Prosječni odnos (%) stvarne i proračunske isporučene ($Q'_{h,del}$) toplinske energije za grijanje
do 1945	FBiH	233,52	F	294,36	148,81	53%
	RS FBiH	272,57	G	344,99	177,38	56%
	RJ FBiH	135,91	D	167,79	77,40	46%
od 1946 do 1965	FBiH	207,93	E	296,30	142,15	52%
	RS FBiH	231,65	F	331,57	159,97	52%
	RJ FBiH	134,93	C	187,78	87,30	51%
od 1966 do 1973	FBiH	156,13	D	223,82	158,72	75%
	RS FBiH	176,23	D	251,80	170,01	70%
	RJ FBiH	85,81	B	125,88	119,21	90%
od 1974 do 1987	FBiH	152,31	D	220,42	150,77	72%
	RS FBiH	174,84	D	252,31	172,06	72%
	RJ FBiH	78,11	B	115,37	80,61	72%
od 1988 do 2009	FBiH	93,01	B	116,69	66,38	69%
	RS FBiH	118,96	C	159,78	91,86	60%
	RJ FBiH	67,07	B	73,61	46,00	78%
od 2010	FBiH	27,59	A	32,09	16,13	50%
	RS FBiH	-	-	-	-	-
	RJ FBiH	27,59	A	32,09	16,13	50%
UKUPNO	FBiH	171,90	D	242,91	145,59	65%
	RS FBiH	197,05	E	279,21	166,20	64%
	RJ FBiH	98,04	C	136,32	85,08	67%

Analizom podataka iz tablice 4.16 može se uočiti kako prosječne vrijednosti proračunske specifične godišnje potrebne toplinske energije za grijanje ($Q'_{H,nd,cal}$) opadaju sa smanjenjem starosti zgrade, na razini ukupnog uzorka iznosi 171,90 kWh/m^{2}god i predstavlja energetski razred D.

Uspoređujući proračunsku specifičnu godišnju potrebnu toplinsku energiju za grijanje ($Q'_{H,nd,cal}$) školskih zgrada u FBiH iz uzorka s podatcima prema TJZ iz tablice 3.7 može se uočiti kako je proračunska specifična godišnja potrebna toplinska energija na razini ukupnog uzorka približno jednaka (171,9/172,7).

Visoke vrijednosti specifične proračunske godišnje isporučene toplinske energije za grijanje ($Q'_{H,del,cal}$), između ostalog, posljedica su zastarjelih kotlovnica (veliki broj školskih zgrada se grije na ugljen i drvo s niskim stupnjem učinkovitosti kotlova) koje imaju velike gubitke u distribuciji proizvedene toplinske energije. Na slici 4.23 prikazan je prosječni odnos stvarne i proračunske vrijednosti specifične isporučene toplinske energije za grijanje ($Q'_{H,del}$) školskih zgrada u FBiH iz uzorka ukupno prema klimatskim regijama.

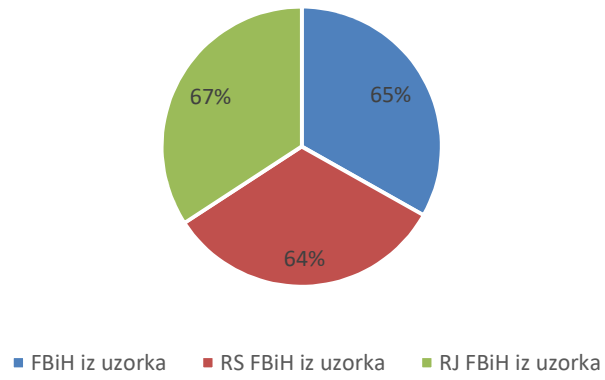

Slika 4.23 Prosječan odnos (%) stvarne i proračunske isporučene toplinske energije za grijanje ($Q'_{H,del}$) školskih zgrada u FBiH iz uzorka ukupno i prema klimatskim regijama u FBiH

Visoke vrijednosti specifične proračunske isporučene toplinske energije za grijanje ($Q'_{H,del,cal}$) školskih zgrada u FBiH ukazuju na neefikasne energetske karakteristike. Usporedbom stvarne i proračunske vrijednosti isporučene toplinske energije za grijanje može se zaključiti da stvarna potrošnja ($Q'_{H,del}$) iznosi prosječno oko 65% potrebne, odnosno da je stvarna za prosječno oko 35% manja od potrebne. Neka od pojašnjenja i razloga za navedeno navedeni su ispod i preuzeti iz dokumenta detaljnih energetskih pregleda:

- Analiza je pokazala da su potrebe zgrade za toplinskom energijom daleko više nego li se to trenutno osigurava lož uljem. Da je zgrada nedovoljno zagrijana, potvrdili su i zaposlenici, koji u najhladnijem razdoblju godine vode zabilješke o postignutim temperaturama u prostoriji, i koje prema njihovim tvrdnjama dostižu vrijednosti od 10°C, što je sa stajališta toplinske ugodnosti i namjene zgrade katastrofalno [101].
- Provedeni proračun teorijski potrebne energije za grijanje pokazuje odstupanja od stvarne potrošnje energije za zadovoljavanje potreba za toplinskom energijom, što ukazuje na činjenicu da uvjeti toplinske ugodnosti nisu zadovoljeni [102].
- Prema riječima odgovornih osoba ne ostvaruje se potrebna toplinska ugodnost, jer unutrašnja temperatura ne prelazi 20°C, a uz to sve prisutna je i visoka infiltracija vanjskog zraka kroz postojeće otvore (neučinkovita stolarija-ventilacijski gubitci). Nedostatak proračunskih sredstava za nabavku energenta za grijanje jedan je od razloga nepostizanja toplinske ugodnosti unutar školske zgrade [103].
- Toplinska ugodnost se djelomično ostvaruje u ovisnosti od prostorije do prostorije. Jedan dio fasadne bravarije je zamijenjen s boljim, energetski učinkovitijim, te su u tim prostorijama ostvaruje toplinska ugodnost, dok u dijelovima zgrade koji imaju staru stolariju toplinska ugodnost se teško postiže. Uočljiv je zabrinjavajući podatak koji pokazuje da su stvarne proračunske toplinske potrebe veće u odnosu na trenutnu potrošnju. To nedvojbeno ukazuje na činjenicu da u predmetnoj zgradi nije ostvarena toplinska ugodnost [104].
- Na temelju prikazanih količina stvarne (prosječne) potrošnje energije i modelirane (proračunske) potrošnje energije vidljivo je da je stvarna potrošnja toplinske energije mnogo manja od proračunski potrebne energije te se dolazi do zaključka da u zgradi nije osigurana zadovoljavajuća razina toplinske udobnosti, tj. ugodan i kvalitetan boravak u pogledu potrebnih temperaturnih vrijednosti zagrijavanja zgrade [105], [106].
- Usporedbom raspoloživih podataka može se zaključiti da je stvarna potrošnja goriva u odnosu na proračunsku potrošnju goriva značajno manja. Navedeno upućuje na to da se određeni prostori ne griju (ostave, hodnici, arhiva itd.) dok se ostali prostori održavaju na nižoj temperaturi od projektne. Razlog je u činjenici da školska zgrada troši toplinsku energiju ovisno o raspoloživim novčanim sredstvima institucija koje skrbe od dobavi goriva, a ne prema stvarnim potrebama za ostvarenje toplinske ugodnosti [107].

Gore navedeni komentari potvrđuju zaključak kako je stvarna potrošnja toplinske energije manja od proračunski potrebne da se zadovolje uvjeti toplinske ugodnosti. Razlozi za navedeno leže u lošim

toplinskim karakteristikama ovojnice i visokoj infiltraciji vanjskog zraka kroz postojeće otvore što uzrokuje velike toplinske gubitke, te uz nedostatak novčanih sredstava koje promatrane ustanove dobivaju od strane osnivača (najčešće su to jedinice lokalne uprave i samouprave) za nabavu potrebnih energenata, predstavljaju osnovne razloge za manju stvarnu potrošnju toplinske energije. Posljedice su ''pothlađenost'' koja se ogleda u nižim temperaturama prostora i negrijanju svih dijelova zgrade (posebice hodnika, školskih dvorana i sanitarnih čvorova) ili nekih učionica zbog manjeg broja učenika.

Pregledom literature također se ukazuje na postojanje razlike (*gap*) ili odstupanja između predviđenih (proračunskih) i stvarnih (izmjerenih) performansi. Van Dronkelaara i ostali utvrdili su da je veličina razlike u odstupanju + 34%, uz standardno odstupanje od 55% na temelju analize 62 zgrade. Ovaj rad utvrđuje da su dominantni uzroci odstupanja specifična nesigurnost u modeliranju, ponašanje stanara, i loša operativna praksa [31].

Druga istraživanja, naročito zgrada koje se projektirane kao niskoenergetske, kako je stvarna potrošnja toplinske energije veća od proračunske ili modelirane vrijednosti. Istraživanje provedeno na pet srednjih škola u Engleskoj koje su trebale biti zgrade s niskom potrošnjom energije je pokazalo da 80% tih zgrada koristi više energije nego što se očekivalo. Navedeni su neki od razloga veće potrošnje energije od očekivane kao što su uvođenje IT-a u nastavni plan i program škola, poboljšani interni ekološki standardi, produljeno radno vrijeme za izvannastavne aktivnosti i loša kontrola [108]. Prema podatcima Instituta za energiju u UK iz 2013. godine pokazuje se kako je stvarna potrošnja toplinske energije u školskim zgradama za 48% veća od proračunski potrebne toplinske energije [109].

Istraživanje 15 školskih zgrada u UK pokazuje kako postoji značajan jaz između proračunskih i stvarnih energetskih karakteristika zgrada, uglavnom zbog nedostatka razumijevanja čimbenika koji utječu na potrošnju energije. Čimbenici koji prema ovom istraživanju imaju najveći utjecaj na jaz ili odstupanje u potrošnji energije su pojednostavljeni modeli proračuna, promjene između projektirane i izgrađene zgrade, korisnici (imaju veliki utjecaj na energetske karakteristike zgrada jer kontroliraju unutarnju temperaturu, ventilaciju, rasvjetu, opremu i toplu vodu), uporaba, održavanje i kontrola zgrade [110].

Najnovija istraživanja pokazuju kako su klimatske promjene i globalno zatopljenje utjecale na povećanje prosječnih mjesečnih temperatura koje služe za proračun godišnje potrebne toplinske energiju za grijanje u BiH. Testiranje novih (ažuriranih) klimatskih podataka za nestambene zgrade u BiH pokazalo je da je potrebna toplinska energija za grijanje nestambenih zgrada u BiH prosječno manja za 17% u regiji sjever, odnosno 19% u regiji jug [111]. Uzimajući u obzir navedeno može se pretpostaviti da je prosječan odnos (%) stvarne i proračunske isporučene toplinske energije za grijanje ipak manji.

Istraživanje koje je provedeno u Sloveniji na 24 školske zgrade u razdoblju 1997. do 1999. godine, na temelju energetskih pregleda, potrošnje energije i kvalitete zraka, pokazalo je da su ove zgrade visoki potrošači energije i da imaju lošu kvalitetu zraka što je izrazilo 60% anketiranih učenika. Pokazano je da su gubitci topline 89% veći od preporučenih ili dopuštenih vrijednosti. U prosjeku ukupna godišnja potrošnja energije analiziranih školskih zgrada iznosi 192 kWh/m^{2}god ili 54 kWh/m^{3}god. Također utvrđeno je da su stvarne energetske potrebe ili potrošnja energije manje nego što su procijenjene ili proračunske potrebe za energijom [61].

Kako su Slovenija i Bosna i Hercegovina bili dijelovi zajedničke prethodne države sa sličnim zajedničkim graditeljskim naslijeđem, prethodno navedeno istraživanje u Sloveniji potvrđuje rezultate ovog istraživanja školskih zgrada u smislu potrošnje energije.

4.4 Analiza troškova potrošnje energije školskih zgrada u FBiH iz uzorka

U 2. poglavlju ovog rada prikazan je pregled literature o troškovima uporabe energije u koje se ubrajaju električna energija, toplinska energija, energija za hlađenje, troškovi opskrbe pitkom vodom, zatim režijski troškovi telefonskih i internetskih usluga, troškovi odvoza komunalnog otpada, troškovi opskrbe, troškovi održavanja higijene i okoliša (materijal za čišćenje, spremačice i domar), te troškovi održavanja sustava grijanja i klimatizacije.

Iz dokumenata detaljnih energetskih pregleda školskih zgrada u FBiH iz uzorka izvršena je analiza stvarnih troškova koji su nastali potrošnjom energenata za grijanje (hlađenje nije razmatrano jer u najvećem broju slučajeva školske zgrade ne rade u ljetnom razdoblju) i troškova nastalih potrošnjom električne energije u svrhu rasvjete, uporabe elektroničkih uređaja i za pripremu tople potrošne vode. U poglavlju 4.3.1 utvrđeno je kako potrošnja toplinske energije iznosi oko 93% od ukupne potrošnje energije dok udio potrošnje električne energije iznosi oko 7%. U ovom poglavlju istražit će se koji energenti se koriste za grijanje te troškovi toplinske i električne energije.

Označavanje troškova (engl. Cost – C) izvršeno je na način da su se oznakama troškova dodavali indeksi sukladno razmatranoj isporučenoj energiji. Ulazni podatci u Prilogu 1 iskazani su u “konvertibilnim markama” (KM), ali će se rezultati ovog istraživanja koji uključuju novčane jedinice iskazivati u eurima (EUR) prema službenoj tečajnoj listi 1,00 EUR = 1,95583 KM.

U analizi troškova energije koristit će se sljedeći troškovi i oznake:

- ukupni godišnji trošak isporučene toplinske energije ($C_{QH,del}$) (EUR/god),
- specifični godišnji trošak isporučene toplinske energije ($C'_{QH,del}$) za grijanje po korisnoj površini (EUR/m^{2}god),

- ukupni godišnji trošak isporučene električne energije ($C_{E,del}$) (EUR/god),
- specifični godišnji trošak isporučene električne energije ($C'_{E,del}$) po korisnoj površini (EUR/m^{2}god),
- ukupni godišnji trošak isporučene energije (toplinske i električne) ($C_{e,del}$) (EUR/god),
- specifični godišnji trošak isporučene energije ($C'_{e,del}$) po korisnoj površini (EUR/m^{2}god),
- jedinični trošak energenata ($UC_{QH,del}$) po isporučenoj toplinskoj energiji (EUR/kWh) i
- jedinični trošak električne energije ($UC_{E,del}$) po isporučenoj električnoj energiji (EUR/kWh).

Ukupni godišnji trošak isporučene energije ($C_{e,del}$) određuje se prema sljedećem izrazu:

$$C_{e,del} = C_{QH,del} + C_{E,del} \left[EUR / god \right] \tag{4.20}$$

Ako je poznat ukupni godišnji trošak isporučene toplinske energije ($C_{QH,del}$) tada se specifični godišnji trošak isporučene toplinske energije ($C'_{QH,del}$) određuje prema sljedećem izrazu:

$$C'_{QH,del} = \frac{C_{QH,del}}{A_k} \left[EUR / m^2 god \right] \tag{4.21}$$

Ako je poznat ukupni godišnji trošak isporučene električne energije ($C_{E,del}$) tada se specifični godišnji trošak isporučene električne energije ($C'_{E,del}$) određuje prema sljedećem izrazu:

$$C'_{E,del} = \frac{C_{E,del}}{A_k} \left[EUR / m^2 god \right] \tag{4.22}$$

Specifični godišnji trošak isporučene energije ($C'_{e,del}$) određuje se prema sljedećem izrazu:

$$C'_{e,del} = \frac{C_{e,del}}{A_k} \left[EUR / m^2 god \right] \tag{4.23}$$

Jedinični trošak energenata ($UC_{QH,del}$) za grijanje određuje se prema sljedećem izrazu:

$$UC_{QH,del} = \frac{UC_F}{CV_F} \left[EUR / kWh \right] \tag{4.24}$$

gdje su:

- UC_F jedinična cijena energenta (*Fuel, F*) po jedinici mjere obračuna energenta (EUR/J.M.), npr. za energent mrki ugljen $UC_F = 0,09$ EUR/kg i
- CV_F ogrjevna vrijednost (*calorific value, CV*) energenta predstavlja isporučenu toplinsku energiju po jedinici mjere energenta (kWh/J.M.), npr. za energent mrki ugljen $M_F = 4,80$ KWh/kg.

Jedinični trošak električne energije ($UC_{E,del}$) po isporučenoj električnoj energiji (EUR/kWh) određuje se na temelju cjenika i obračuna distributera električne energije i ovisi o potrošnji električne energije u nižim ili višim tarifama, angažiranoj vršnoj snazi i drugim parametrima.

Specifični godišnji trošak isporučene toplinske energije ($C'_{QH,del}$) može se odrediti prema sljedećem izrazu:

$$C'_{QH,del} = Q'_{H,del} \cdot UC_{QH,del} \left[EUR / m^2 god \right] \tag{4.25}$$

gdje su:

- $Q'_{H,del}$ specifična godišnja isporučena toplinska energija za grijanje (kWh/m^{2}god) i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Iz izraza 4.25 može se vidjeti kako specifični troškovi za grijanje ovise od potrošnje toplinske energije za grijanje (koja je varijabilna veličina ovisna o karakteristikama ovojnice, toplinskim gubitcima, ponašanju korisnika i drugim varijablama) i jediničnog troška energenta koji ovisi o tržišnoj cijeni i na koju se ne može utjecati. Zbog navedenog smanjenje troškova za grijanje moguće je postići smanjenjem potrošnje toplinske energije (primjenom mjera za poboljšanje energetske učinkovitosti ovojnice) i/ili zamjenom energenta uz poboljšanje učinkovitosti sustava grijanja.

Specifični godišnji trošak električne energije ($C'_{E,del}$) može se odrediti prema sljedećem izrazu:

$$C'_{E,del} = E'_{del} \cdot UC_{E,del} \left[EUR / m^2 god \right] \tag{4.26}$$

gdje su:

- E'_{del} specifična godišnja isporučena električna energija (kWh/m^{2}god) i

- $UC_{E,del}$ jedinični trošak električne energije po isporučenoj električnoj energiji (EUR/kWh).

Iz izraza 4.26 može se vidjeti kako specifični troškovi za električnu energiju ovise od potrošnje električne energije i jediničnog troška električne energije koji ovisi o tržišnoj cijeni. Zbog navedenog smanjenje troškova za potrošnju električne energije moguće je postići smanjenjem potrošnje električne energije uporabom energetski učinkovitih uređaja, opreme i rasvjete.

Za gore opisane troškove izvršena je statistička analiza čiji su sažeti rezultati prikazani u tablici 4.17 i slikama 4.24 i 4.25.

Tablica 4.17 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema stvarnim vrijednostima jediničnog troška energenata ($UC_{QH,del}$), jediničnog troška električne energije ($UC_{E,del}$), specifičnog godišnjeg troška isporučene toplinske energije ($C'_{QH,del}$) i specifičnog godišnjeg troška električne energije ($C'_{E,del}$)

Varijabla	n	x_{min}	x_{max}	R_x	$\bar{X}$	M_e	σ_x	V	q_1	q_3	V_q
$UC_{QH,del}$ (EUR/kWh)	185	0,012	0,140	0,128	0,059	0,064	0,033	56,0%	0,022	0,087	59,6%
$C'_{QH,del}$ (EUR/m²god)	185	0,51	23,28	22,77	6,91	5,59	4,24	61,3%	3,67	9,56	44,6%
$UC_{E,del}$ (EUR/kWh)	184	0,080	0,195	0,115	0,128	0,126	0,019	14,6%	0,115	0,139	9,4%
$C'_{E,del}$ (EUR/m²god)	184	0,09	5,82	5,73	1,42	1,31	0,73	51,3%	0,96	1,70	27,8%

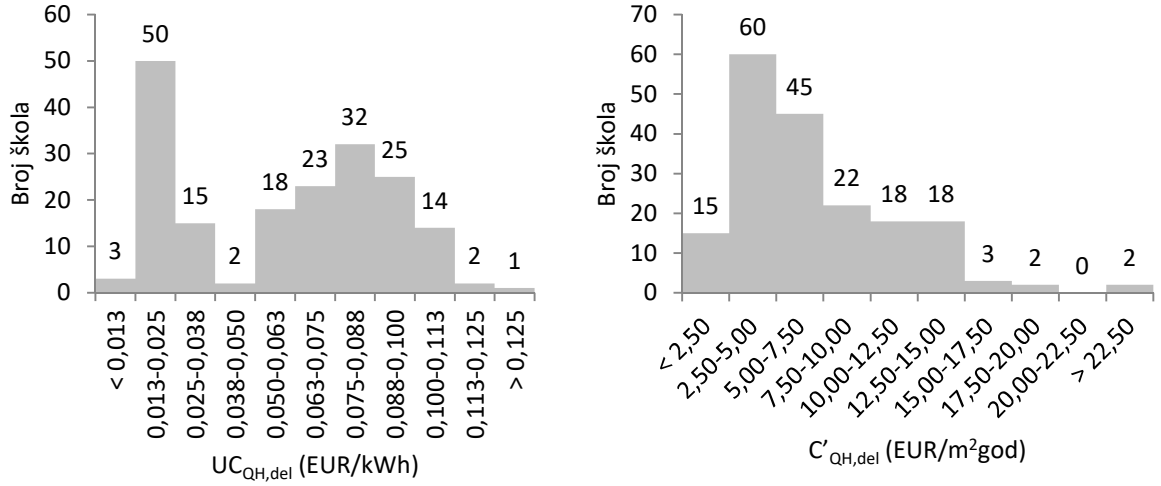

Slika 4.24 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na jedinični troška energenata ($UC_{QH,del}$) i specifični godišnji trošak toplinske energije ($C'_{QH,del}$)

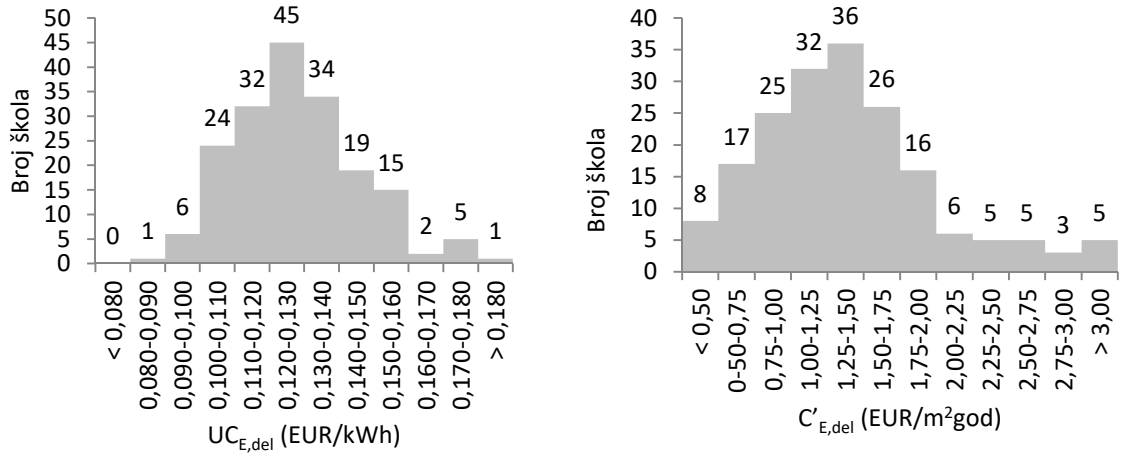

Slika 4.25 Histogrami broja školskih zgrada u FBiH iz uzorka u odnosu na jedinični trošak električne energije ($UC_{E,del}$) i specifični trošak električne energije ($C'_{E,del}$)

Prosječni specifični godišnji trošak $C'_{QH,del}$ za isporučenu toplinsku energiju za grijanje školskih zgrada u FBiH iz uzorka iznosi 6,91 EUR/m^{2}god, dok prosječni specifični trošak za utrošenu električnu energiju ($C'_{E,del}$) iznosi 1,42 EUR/m^{2}god.

Specifični godišnji trošak energenata ($C'_{QH,del}$) u rasponu vrijednosti od 2,50 do 7,50 EUR/m^{2}god ima 105 školskih zgrada ili 56,8%, a u rasponu od oko 3,67 do 9,56 EUR/m^{2}god nalazi se 50% školskih zgrada u FBiH iz uzorka. Specifični godišnji trošak električne energije ($C'_{E,del}$) u rasponu vrijednosti od 0,50 do 2,00 EUR/m^{2}god ima 152 školske zgrade ili 82,6%, a u rasponu od oko 0,96 do 1,70 EUR/m^{2}god nalazi se 50% školskih zgrada u FBiH iz uzorka.

Analizirajući disperziju rezultata statističke analize koeficijent varijacije za $UC_{QH,del}$, $C'_{QH,del}$ i $C'_{E,del}$ iznosi od 50% do 70% što predstavlja jaku disperziju te upućuje da je potrebno dodatno istražiti $UC_{QH,del}$ i $C'_{QH,del}$ jer imaju veliku vrijednost relativne mjere disperzije središnjih 50% podataka.

U tablici 4.18 dan je sažeti prikaz prosječnih vrijednosti specifičnog godišnjeg troška za isporučenu toplinsku energiju ($C'_{QH,del}$), specifičnog godišnjeg troška za utrošenu električnu energiju ($C'_{E,del}$) i ukupnog specifičnog godišnjeg troška isporučene energije ($C'_{e,del}$) koji predstavlja zbroj specifičnog godišnjeg troška za isporučenu toplinsku energiju i specifičnog godišnjeg troška za utrošenu električnu energiju školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i po klimatskim regijama. U

tablici 4.18 također je prikazan udio pojedinačnih komponenti troškova isporučene toplinske i električne energije u ukupnim troškovima isporučene energije.

Tablica 4.18 Podatci o prosječnim vrijednostima specifičnog godišnjeg troška za isporučenu toplinsku energiju ($C'_{QH,del}$), specifičnog godišnjeg troška za utrošenu električnu energiju ($C'_{E,del}$), ukupnog specifičnog godišnjeg troška isporučene energije ($C'_{e,del}$) te udjela troškova u ukupnim troškovima energije školskih zgrada u FBiH iz uzorka u odnosu na razdoblje izgradnje i klimatske regije

ŠKOLSKE ZGRADE U FBIH IZ UZORKA		Prosječni stvarni specifični trošak za isporučenu toplinsku energiju $C'_{QH,del}$ (EUR/m^2 god)	Prosječni stvarni specifični trošak za električnu energiju $C'_{E,del}$ (EUR/m^2 god)	Ukupni prosječni trošak za isporučenu toplinsku energiju i električnu energiju $C'_{e,del}$ EUR/m^{2}god)	Udio troškova isporučene toplinske energije u ukupnim troškovima energije (%)	Udio troškova električne energije u ukupnim troškovima energije (%)
do 1945	FBiH	8,67	1,77	10,44	83,1%	16,9%
	RS FBiH	8,87	1,72	10,59	83,8%	16,2%
	RJ FBiH	8,17	1,90	10,07	81,1%	18,9%
od 1946 do 1965	FBiH	6,46	1,31	7,77	83,2%	16,8%
	RS FBiH	6,89	1,25	8,13	84,7%	15,3%
	RJ FBiH	5,16	1,50	6,66	77,5%	22,5%
od 1966 do 1973	FBiH	7,28	1,34	8,62	84,4%	15,6%
	RS FBiH	7,40	1,36	8,76	84,5%	15,5%
	RJ FBiH	6,85	1,28	8,12	84,3%	15,7%
od 1974 do 1987	FBiH	7,00	1,42	8,42	83,1%	16,9%
	RS FBiH	7,61	1,39	9,00	84,5%	15,5%
	RJ FBiH	4,99	1,52	6,51	76,6%	23,4%
od 1988 do 2009	FBiH	5,17	1,65	6,82	75,9%	24,1%
	RS FBiH	5,22	1,66	6,88	75,9%	24,1%
	RJ FBiH	5,13	1,63	6,76	75,87%	24,13%
od 2010	FBiH	0,51	1,09	1,60	31,7%	68,3%
	RS FBiH	-	-	-	-	-
	RJ FBiH	0,51	1,09	1,60	31,7%	68,3%
UKUPNO	FBiH	6,91	1,41	8,32	83,1%	16,9%
	RS FBiH	7,38	1,38	8,75	84,3%	15,7%
	RJ FBiH	5,54	1,51	7,05	78,6%	21,4%

Analizirajući tablicu 4.18 s prosječnim vrijednostima stvarnih specifičnih troškova isporučene toplinske energije ($C'_{QH,del}$) i stvarnih specifičnih troškova potrošnje električne energije ($C'_{E,del}$), ukupno i po klimatskim regijama u FBiH iz uzorka može se zaključiti da udio troškova toplinske energije na razini ukupnog uzorka iznosi oko 83% (što je oko 10% manje u odnosu na prosječnu potrošnju toplinske energije na razini ukupnog uzorka koja iznosi oko 93%) a za električnu energiju udio iznosi oko 17% ili

oko 10% više u odnosu na potrošnju električne energije. Kako je u klimatskoj regiji jug FBiH udio potrošnje električne energije nešto viši u odnosu na regiju sjever tako su i troškovi potrošnje električne energije viši u odnosu na regiju sjever FBiH. Također, i ovdje za razdoblje izgradnje poslije 2010. godine u uzorku se nalazi 1 škola tako da su rezultati za troškove isporučene toplinske energije indikativni i nisu reprezentativni.

Od dostupnih raspoloživih i usporedivih podataka iz poglavlja 2.6 poznati su podatci za javnu zgradu Studentskog centra u Mostaru (koja se nalazi u regiji jug FBiH) za koju prosječni specifični godišnji troškovi potrošnje toplinske energije iznose 5,85 EUR/m^2 a prosječni specifični troškovi električne energije iznose 6,63 EUR/m^2 [45]. Prosječni specifični godišnji troškovi isporučene toplinske energije ($C'_{QH,del}$) za školske zgrade iz uzorka u regiji jug FBiH iznose 5,54 EUR/m^{2}god što približno odgovara iznosu od 5,85 EUR/m^2. Podatci o specifičnim troškovima potrošnje električne energije ($C'_{E,del}$) za školske zgrade iz uzorka su puno manji od prosječnih specifičnih troškova električne (6,63 EUR/m^2) radi potpuno druge namjene zgrade i režima rada Studentskog centra u Mostaru.

Ukupan specifični godišnji trošak isporučene energije ($C'_{e,del}$) za školske zgrade u FBiH iz uzorka iznosi 8,32 EUR/m^{2}god. Za usporedbu poznati su prosječni troškovi za energiju u školama u USA koji iznose 9,13 EUR /m^{2}god [42].

Međutim, gore prikazani prosječni godišnji specifični troškovi za isporučenu toplinsku energiju ($C'_{QH,del}$) za grijanje predstavljaju prosječne vrijednosti bez obzira na energent koji pojedina školska zgrada koristi. Zbog navedenog kao i velike disperzije ovih podataka, potrebno je troškove vezane za potrošnju isporučene toplinske energije ($C'_{QH,del}$) za grijanje (koja je posljedica toplinskih karakteristika stanja ovojnice i učinkovitosti sustava grijanja) promatrati u odnosu na energent koji se koristi za dobivanje toplinske energije. Energenti koji se koriste za dobivanje toplinske energije iz ukupnog uzorka su sljedeći i prikazani su na slici 4.26:

- Ugljen i drvo zajednički su razmatrani kao jedna skupina jer se u većini slučajeva zajednički koriste (oznaka E1),
- Pelet (oznaka E2),
- Lož ulje (LU) i ekstra lako lož ulje (ELLU) (oznaka E3),
- Daljinsko grijanje (DG) putem gradskih toplana (oznaka E4),
- Prirodni plin (oznaka E5), i

- Električna energija (oznaka E6).

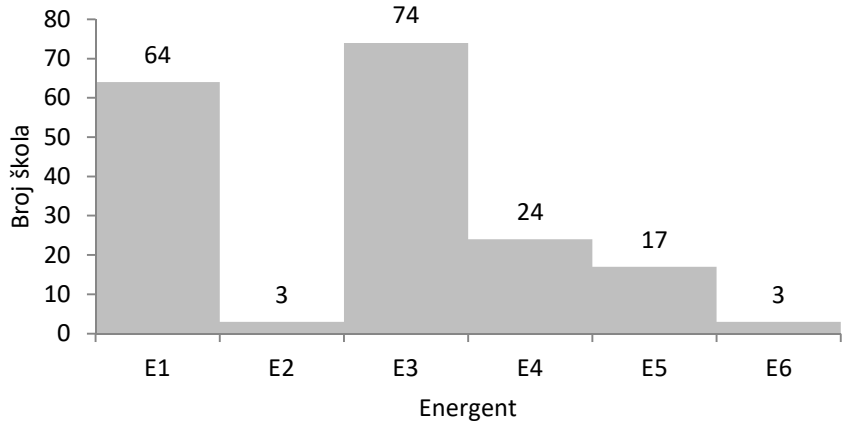

Slika 4.26 Histogram broja školskih zgrada u FBiH iz uzorka u odnosu na korišteni energent za grijanje

Analizirajući sliku 4.26 u odnosu na korišteni energent školskih zgrada u FBiH iz uzorka primjetna je velika zastupljenost fosilnih goriva (lož ulje i ugljen) gdje se najveći broj školskih zgrada grije na lož ulje (ekstra lako lož ulje), ugljen i drvo što zajednički čini oko 75%. U tablici 4.19 prikazani su rezultati statističke analize prosječnog jediničnog troška energenata ($UC_{QH,del}$) za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Tablica 4.19 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema vrijednostima prosječnog jediničnog troška energenata ($UC_{QH,del}$) za grijanje

Energent	n	x_{min}	x_{max}	R_x	$\bar{X}$	M_e	σ_x	V	q_1	q_3	V_q
$UC_{QH,del}$ - E1 (EUR/kWh)	64	0,012	0,038	0,026	0,019	0,018	0,005	25,0%	0,016	0,022	16,9%
$UC_{QH,del}$ - E2 (EUR/kWh)	3	0,031	0,052	0,021	0,041	0,038	0,009	21,5%	0,035	0,045	13,1%
$UC_{QH,del}$ - E3 (EUR/kWh)	74	0,070	0,115	0,045	0,089	0,088	0,011	11,9%	0,083	0,096	7,3%
$UC_{QH,del}$ - E4 (EUR/kWh)	24	0,018	0,094	0,076	0,062	0,064	0,019	30,7%	0,051	0,077	19,9%
$UC_{QH,del}$ - E5 (EUR/kWh)	17	0,054	0,073	0,019	0,062	0,062	0,005	8,0%	0,058	0,065	5,5%
$UC_{QH,del}$ - E6 (EUR/kWh)	3	0,050	0,140	0,090	0,105	0,124	0,039	37,2%	0,087	0,132	20,4%
Prosjek $UC_{QH,del}$ (EUR/kWh)	185	0,012	0,140	0,128	0,059	0,064	0,033	56,0%	0,022	0,087	59,6%

Analizirajući podatke iz tablice 4.19 sa stajališta prosječnog jediničnog troška energenata ($UC_{QH,del}$) za grijanje po utrošenoj isporučenoj energiji (EUR/kWh) u FBiH iz uzorka može se uočiti kao se najniži prosječni jedinični troškovi odnose na energent ugljen i drvo koji iznosi 0,019 EUR/kWh.

U zadnjih 10-tak godina počeo je se koristiti pelet kao energent za dobivanje toplinske energije čiji prosječni trošak po utrošenoj isporučenoj energiji iznosi 0,041 EUR/kWh. Zatim slijede prirodni plin čiji prosječni trošak iznosi 0,062 EUR/kWh i daljinsko grijanje putem gradskih toplana čiji prosječni trošak iznosi 0,062 EUR/kWh. U grupu najskupljih energenata spada lož ulje i ekstra lako lož ulje s prosječnim jediničnim troškom od 0,089 EUR/kWh te električna energija čiji prosječni jedinični trošak po utrošenoj isporučenoj energiji iznosi 0,105 EUR/kWh.

Koeficijent varijacije za $UC_{QH,del}$ sada je slab do umjeren, posebice za najčešće korišteni energent E3. Na slici 4.27 prikazan je odnos (%) pojedinačnih prosječnih troškova energenata u odnosu na prosječnu vrijednost jediničnog troška po utrošenoj isporučenoj energiji koji iznosi 0,059 EUR/kWh. Zgrade koje se griju na energent ugljen i drvo imaju male specifične troškove, a kod primjene mjera za poboljšanje energetskih karakteristika imaju relativno male uštede i dugo razdoblje povrata investicije. Međutim, osim financijskih pokazatelja kojima se vrši ocjena investicija mjera za poboljšanje energetskih karakteristika zgrada bitno je i smanjenje utjecaja na okoliš zamjenom fosilnih energenata s energentima koji su neutralni u smislu emisije CO_2.

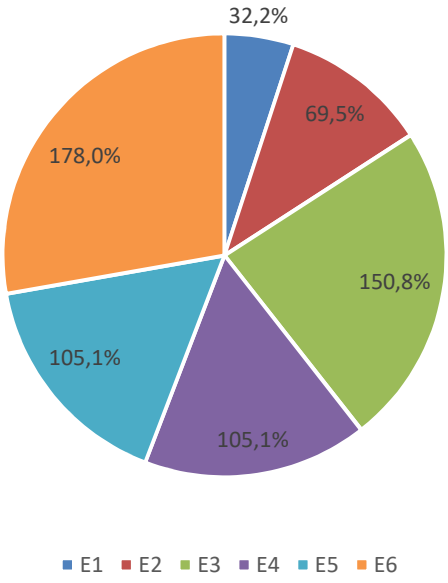

Slika 4.27 Prikaz odnosa pojedinačnih vrijednosti prosječnog jediničnog troška energenata za grijanje po utrošenoj isporučenoj energiji u odnosu na prosječnu vrijednost školskih zgrada u FBiH iz uzorka

Zatim je izvršena statistička analiza stvarnih specifičnih godišnjih troškova ($C'_{QH,del}$) prema energentu koji se koristi za grijanje i prikazana u tablici 4.20.

Tablica 4.20 Podatci deskriptivne statistike školskih zgrada u FBiH iz uzorka prema vrijednostima specifičnog godišnjeg troška isporučene toplinske energije ($C'_{QH,del}$) za grijanje u odnosu na korišteni energent

Energent	n	x_{min}	x_{max}	R_x	$\bar{X}$	M_e	σ_x	V	q_1	q_3	V_q
$C'_{QH,del}$ - E1 (EUR/m²god)	64	1,40	9,36	7,96	3,89	3,61	1,55	39,9%	2,76	4,89	27,9%
$C'_{QH,del}$ - E2 (EUR/m²god)	3	0,51	5,21	4,71	2,51	1,80	1,99	79,2%	1,15	3,51	50,5%
$C'_{QH,del}$ - E3 (EUR/m²god)	74	2,01	23,28	21,27	8,05	6,37	4,54	56,4%	4,89	10,30	35,6%
$C'_{QH,del}$ - E4 (EUR/m²god)	24	3,97	15,96	11,99	10,91	11,24	3,28	30,1%	9,33	13,45	18,1%
$C'_{QH,del}$ - E5 (EUR/m²god)	17	4,88	13,55	8,67	8,76	8,48	2,84	32,4%	6,23	11,17	28,4%
$C'_{QH,del}$ - E6 (EUR/m²god)	3	0,69	10,12	9,43	5,32	5,16	3,85	72,4%	2,92	7,64	44,6%
Prosjek $C'_{QH,del}$ (EUR/m²god)	185	0,51	23,28	22,77	6,91	5,59	4,24	61,3%	3,67	9,56	44,6%

Analizirajući podatke iz tablice 4.20 sa stajališta jediničnog troška isporučene toplinske energije ($C'_{QH,del}$) za grijanje školskih zgrada u FBiH na razini ukupnog uzorka može se uočiti velika disperzija. Međutim, promatrajući rezultate po pojedinim energentima osim energenata E2 i E6 koji imaju samo po 3 uzorka, jedino energent E3 ima koeficijent varijacije veći od 50%.

Zatim je, u odnosu na energente koji se koristi za dobivanje toplinske energije, izvršena usporedba stvarnog specifičnog proračunskog godišnjeg troška isporučene toplinske energije ($C'_{QH,del}$) i proračunskog specifičnog godišnjeg troška isporučene toplinske energije ($C'_{QH,del,cal}$) za grijanje (prema modeliranoj ili proračunskoj toplinskoj energiji za grijanje) što je prikazano u tablici 4.21.

Najniži prosječni stvarni specifični godišnji trošak energenata ($C'_{QH,del}$) za grijanje po korisnoj površini (EUR/m²god) imaju školske zgrade koje se griju na energent pelet (E2) i on iznosi 2,51 EUR/m²god iako njegov prosječni jedinični trošak ($UC_{QH,del}$) nije najniži (0,041 EUR/kWh). Osnovni razlog za navedeno leži maloj stvarnoj isporučenoj ($Q_{H,del}$) toplinskoj energiji za grijanje (posljedica boljih toplinskih karakteristika ovojnice i manjih toplinskih gubitaka) i visokom stupnju učinkovitosti sustava grijanja (η_{sys}). I prosječni proračunski (modelirani trošak u odnosu na proračunsku isporučenu toplinsku energiju $Q_{H,del,cal}$) za grijanje (stvarna potrošnja toplinske energije iznosi 54% od potrebne proračunske potrošnje) je najniži i iznosi 4,25 EUR/m²god.

Tablica 4.21 Podatci o prosječnim vrijednostima stvarne specifične isporučene toplinske energije ($Q'_{H,del}$), stupnja učinkovitosti sustava grijanja (η_{sys}), jediničnog troška energenata ($UC_{QH,del}$), stvarnog specifičnog godišnjem troška energenata ($C'_{QH,del}$) i proračunskog specifičnog godišnjeg troška energenta ($C'_{QH,del,cal}$) školskih zgrada u FBiH iz uzorka

Energent	Prosječna stvarna isporučena toplinska energija $Q'_{h,del}$ (kWh/m²god)	Prosječni stupanj učinkovitosti sustava grijanja	Prosječni jedinični trošak energenata $UC_{QH,del}$ (EUR/kWh)	Prosječni stvarni specifični trošak energenata $C'_{QH,del}$ (EUR/m²god)	Prosječni proračunski specifični trošak energenata $C'_{QH,del,cal}$ (EUR/m²god)	Usporedba (%) stvarnog i proračunskog specifičnog troška energenta za grijanje
E1	206,58	0,63	0,019	3,89	6,33	70%
E2	54,20	0,88	0,041	2,51	4,25	54%
E3	90,06	0,76	0,089	8,05	16,65	56%
E4	181,47	0,87	0,062	10,91	13,84	86%
E5	141,09	0,80	0,062	8,76	15,75	63%
E6	44,00	0,96	0,105	5,32	13,90	41%
Prosjek	145,59	0,73	0,059	6,91	12,39	65%

Ugljen i drvo (E1) su sljedeći energent koji imaju nizak prosječan stvarni specifični godišnji trošak energenata ($C'_{QH,del}$) za grijanje koji iznosi 3,89 EUR/m²god iako je njihov prosječni jedinični trošak ($UC_{QH,del}$) najniži (0,019 EUR/kWh). Razlog za navedeno leži u najvećoj stvarnoj specifičnoj isporučenoj toplinskoj energiji ($Q'_{H,del}$) za grijanje (loše toplinske karakteristike ovojnice) i najnižem prosječnom stupnju učinkovitosti sustava grijanja (η_{sys}) koji iznosi 0,63. Prosječni proračunski (modelirani) specifični trošak energenta E1 za grijanje iznosi 6,33 EUR/m²god. Ipak podmirenje stvarne toplinske energije u odnosu na proračunsku kao i troškova za energent E1 iznosi 70% prvenstveno zbog činjenice niskih specifičnih troškova. Kod prijedloga termotehničkih mjera za poboljšanje energetske učinkovitosti ovih školskih zgrada obavezno se predlažu mjere na zamjeni postojećih kotlova energetski efikasnijim kotlovima na biomasu i izbacivanje ugljena kao fosilnog energenta.

Električna energija (E6) je energent koji se koristi za 3 manje školske zgrade iz uzorka smještenih u regiji jug FBiH. Prosječna stvarna potrošnja toplinske energije iznosi samo 41% potrebne (proračunske) što je utjecalo na relativno nizak prosječan stvarni specifični godišnji trošak energenata ($C'_{QH,del}$) za grijanje koji iznosi 5,32 EUR/m²god iako je stvarni prosječni jedinični trošak ($UC_{QH,del}$) najviši (0,105 EUR/kWh). Prosječni proračunski (modelirani) trošak energenta E za grijanje iznosi 13,90 EUR/m²god.

Zbog visokih jediničnih troškova i visokih emisija CO_2 električnu energiju treba izbjegavati kao energent koji se koristi za grijanje.

Na energente lož ulje i ekstra lako lož ulje (E3) grije se najveći broj školskih zgrada iz uzorka (njih 74 ili 40%) čiji prosječan stvarni specifični godišnji trošak ($C'_{QH,del}$) iznosi 8,05 EUR/m^{2}god. Razlog leži u maloj stvarnoj specifičnoj isporučenoj toplinskoj energiji ($Q'_{H,del}$) za grijanje koja iznosi 90,06 kWh/m^{2}god (od 74 školske zgrade koje se griju na energent E3 34 se nalaze u regiji jug FBiH) i koja iznosi 56% od potrebne proračunske toplinske energije za grijanje. Prosječni proračunski (modelirani) trošak energenta E3 za grijanje je najviši od svih energenata i iznosi 16,65 EUR/m^{2}god. Kod prijedloga termotehničkih mjera za poboljšanje energetske učinkovitosti ovih školskih zgrada obavezno se predlaže izbacivanje energenta lož ulja kao fosilnog goriva (smanjenje utjecaja na okoliš), s visokim jediničnim i specifičnim troškovima, uz prijedloge uvođenja energenata na biomasu ako ne postoji neki drugi mogući izvor energije.

Na prirodni plin (E5) grije se oko 9% školskih zgrada u FBiH iz uzorka, i to su zgrade smještene u gradu Sarajevu koji imaju mogućnost povezivanja na sustav opskrbe. Prosječan stvarni specifični godišnji trošak ($C'_{QH,del}$) iznosi 8,76 EUR/m^{2}god, a prosječni proračunski trošak energenta E5 za grijanje (stvarna potrošnja toplinske energije iznosi 63% od potrebne proračunske potrošnje) iznosi 15,75 EUR/m^{2}god što je nešto malo niže od specifičnih troškova energenta E3. Uz mjere na poboljšanju energetske učinkovitosti ovojnice i povećanju učinkovitosti sustava regulacije grijanja moguće je utjecati na smanjenje specifičnih godišnjih troškova ($C'_{QH,del}$) za grijanje ovog energenta E5.

Na daljinsko grijanje (E4) grije se oko 13% školskih zgrada u FBiH iz uzorka, i to su školske zgrade smještene u gradovima koji imaju gradsko grijanje putem toplana. Prosječan stvarni specifični godišnji trošak ($C'_{QH,del}$) je najviši i iznosi 10,91 EUR/m^{2}god što je posljedica najvećeg stupnja stvarne potrošnje toplinske energije koji iznosi 86% od potrebne proračunske. Prosječni proračunski (modelirani) trošak energenta za grijanje je također visok i iznosi 13,84 EUR/m^{2}god. U najvećem broju slučajeva kod ovakvog načina grijanja troškovi grijanja se plaćaju prema korisnoj površini grijanja (m^2) a ne prema stvarno utrošenoj toplinskoj energiji. Zbog navedenog u prijedlogu mjera za poboljšanje energetske učinkovitosti ovih školskih zgrada predlažu se mjere poboljšanja energetske učinkovitosti ovojnice (smanjenje toplinskih gubitaka) i prelazak na obračun troškova za grijanje u odnosu na stvarno izmjerenu potrošenu toplinsku energiju.

4.5 Zaključna razmatranja o potrošnji i troškovima energije školskih zgrada u FBiH iz uzorka

Izvršena je analiza energetskih karakteristika školskih zgrada u FBiH na temelju statističke obrade prikupljenih podataka iz DEA o karakteristikama zgrada, potrošnji i troškovima uporabe toplinske i električne energije u odnosu na razdoblje izgradnje za uzorak od 185 školskih zgrada koji u odnosu na ukupan broj svih zgrada namijenjenih obrazovanju u FBiH čini 12,7%. Sa stajališta klimatskih uvjeta 47 školskih zgrada u FBiH iz uzorka je smješteno u regiji jug (RJ) FBiH koja ima mediteransku ili submediteransku klimu, a 138 školskih zgrada u FBiH je smješteno u regiji sjever (RS) FBiH koja ima kontinentalnu klimu.

U odnosu na opće i geometrijske karakteristike školskih zgrada utvrđeno je slijedeće:

- prosječna starost iznosi preko 53 godine,
- prosječna korisna površina zajedno sa školskim dvoranama iznosi 2.332,00 m^2,
- prosječna površina ovojnice iznosi 4.707,00 m^2,
- prosječna vrijednost faktora kompaktnosti f_o iznosi 0,56 m^{-1},
- prosječan udio površine zidova i stropova u ukupnoj površini ovojnice iznosi oko 30 %, površina podova ima udio od oko 27 % i površina otvora oko 13 %,
- prosječna U - vrijednost za zidove iznosi 1,48 W/m^2K, za podove 1,95 W/m^2K, za stropove 1,82 W/m^2K, za otvore 2,90 W/m^2K i za ukupnu ovojnicu iznosi 1,87 W/m^2K,
- prosječne U-vrijednosti pojedinih elemenata ovojnice višestruko premašuju dopuštene vrijednosti prema propisima što ukazuje na nedostatak slojeva toplinske izolacije i
- stvarna vrijednost koeficijenta transmisijskog gubitka topline približno je 2,3 puta veća od dopuštene vrijednosti.

Analizom potrošnje toplinske i električne energije utvrđeno je slijedeće:

- prosječna vrijednost specifične isporučene toplinske energije za grijanje ($Q'_{H,del}$) iznosi 145,59 kWh/m^2god uz veliku disperziju vrijednosti,
- prosječna vrijednost specifične isporučene toplinske energije za grijanje ($Q'_{H,del}$) u RS FBiH iznosi 166,20 kWh/m^2god, a u RJ FBiH iznosi 85,08 kWh/m^2god,
- prosječna vrijednost isporučene električne energije (E'_{del}) iznosi 11,32 kWh/m^2god,

- udio potrošnje toplinske energije u ukupnoj potrošnji energije iznosi oko 93%, a udio električne energije iznosi oko 7%,
- za zadovoljavanje stvarnih potreba prosječna proračunska specifična potrebna toplinska isporučena energija za grijanje ($Q'_{H,nd}$) ima prosječnu vrijednost od 242,91 kWh/m^{2}god i
- stvarna prosječna vrijednost specifične isporučene toplinske energije za grijanje ($Q'_{H,del}$) je za oko 35% manja od potrebne proračunske vrijednosti što upućuje da toplinska ugodnost nije zadovoljena.

U nastavku je izvršena analiza međusobnih odnosa između pojedinih karakteristika ili varijabli školskih zgrada u FBiH iz uzorka u odnosu na stvarne specifične isporučene toplinske energije za grijanje ($Q'_{H,del}$). Odnosi su prikazani u vidu dijagrama rasipanja.

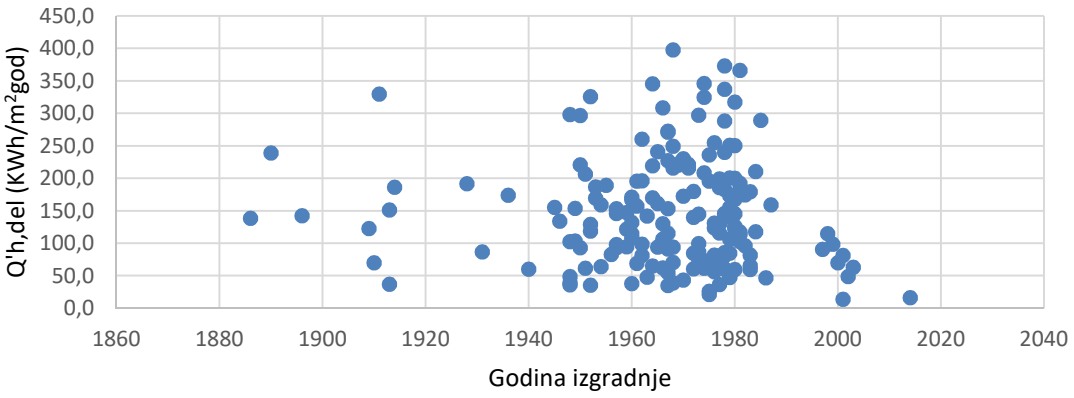

Slika 4.28 Dijagram rasipanja stvarne specifične isporučene toplinske energije ($Q'_{H,del}$) u odnosu na godine izgradnje školskih zgrada u FBiH iz uzorka

Dijagram na slici 4.28 rasipanja stvarne specifične isporučene toplinske energije ($Q'_{H,del}$) u odnosu na godine izgradnje školskih zgrada u FBiH iz uzorka pokazuje veliko rasipanje podataka i teško se može procijeniti povezanost između promatranih varijabli. Kao mjera međusobne povezanosti između dvije varijable najčešće se koristi koeficijent linearne korelacije uz određivanje statističke značajnosti ili p-vrijednosti. Koeficijent linearne korelacije između isporučene toplinske energije ($Q'_{H,del}$) i godine izgradnje iznosi 0,08 što ukazuje na neznatnu korelaciju a p-vrijednost statističke značajnosti iznosi 0,295 (što je veće od gornje granice 0,05) ukazuje da koeficijent linearne korelacije nije statistički značajan. Može se zaključiti da ne postoji statistički značajna povezanost između stvarne specifične isporučene toplinske energije ($Q'_{H,del}$) i godine izgradnje.

Zatim je analiziran odnos između stvarne specifične isporučene toplinske energije ($Q'_{H,del}$) i U – vrijednosti ovojnice kao jednog od temeljnih karakteristika kojima se mjeri toplinska zaštita ovojnice. Na dijagramu slike 4.29 prikazan je odnos za ukupan uzorak, a na dijagramu slike 4.30 prikazani su odnosi, ako se promatraju odnosi prema klimatskim regijama kako bi se umanjili utjecaji klime na potrošnju toplinske energije.

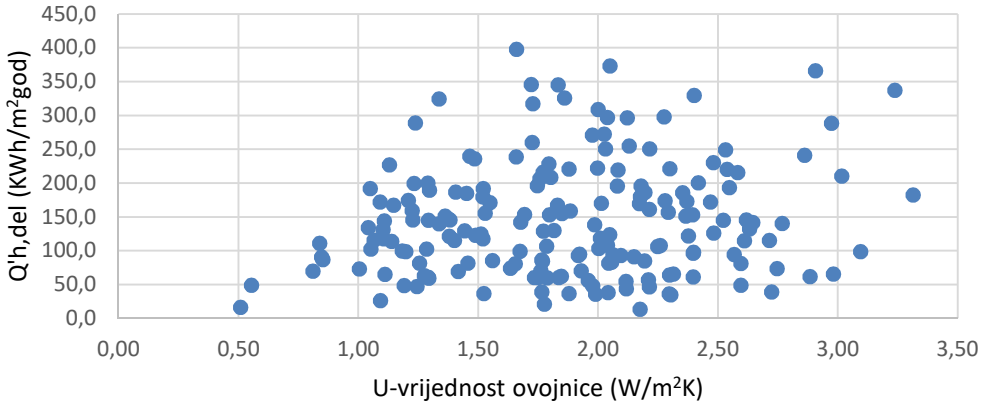

Slika 4.29 Dijagram rasipanja stvarne specifične isporučene toplinske energije ($Q'_{H,del}$) u odnosu na U-vrijednost ovojnice školskih zgrada u FBiH iz uzorka

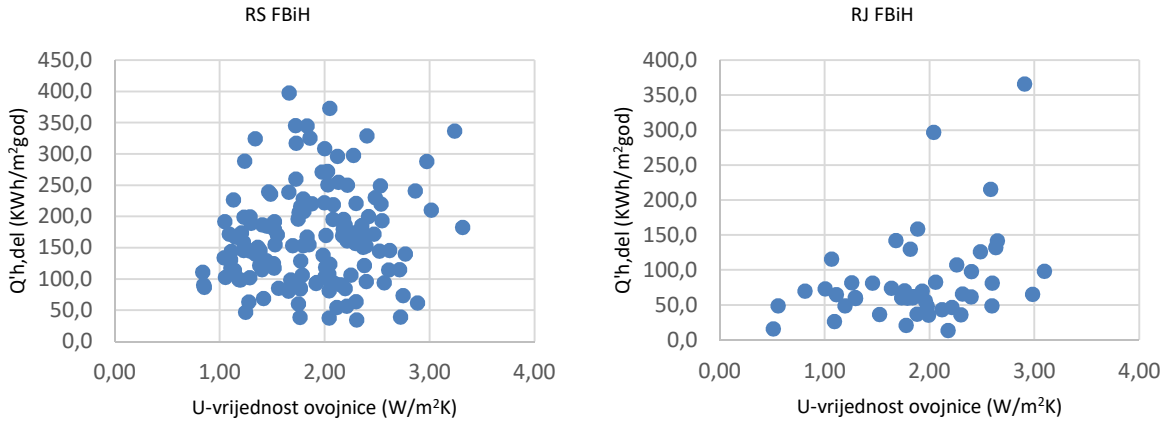

Slika 4.30 Dijagrami rasipanja stvarne specifične isporučene toplinske energije ($Q'_{H,del}$) u odnosu na U-vrijednost ovojnice prema klimatskim regijama RS i RJ školskih zgrada u FBiH iz uzorka

Koeficijent linearne korelacije između isporučene toplinske energije ($Q'_{H,del}$) i U-vrijednost ovojnice svih školskih zgrada u FBiH iznosi 0,16 što ukazuje na neznatnu korelaciju, a p-vrijednost statističke značajnosti iznosi 0,034 ($p<0,05$) ukazuje da koeficijent linearne korelacije značajan. Vrijednost koeficijenta linearne korelacije u RS FBiH on iznosi 0,12 (neznatna korelacija), a p-vrijednost 0,169 (nije

statistički značajan). Vrijednost koeficijenta linearne korelacije u RJ FBiH iznosi 0,36 (relativno slaba korelacija), a p-vrijednost 0,012 (statistički značajan). Može se zaključiti da postoji statistički značajna ali ipak neznatna povezanost između isporučene toplinske energije ($Q'_{H,del}$) i U-vrijednost ovojnice u FBiH.

Prethodna analiza je pokazala kako potrošnja isporučene toplinske energije neznatno povezana s ključnim karakteristikama kao što je godina izgradnje (starost građevine) i U-vrijednost ovojnice kao parametra toplinskih gubitaka. Navedeni rezultati analize potvrđuju zaključke iz poglavlja 4.3 kako je stvarna potrošnja toplinske energije ne odražava zahtjeve za stvarnim toplinskim potrebama.

Analizom troškova nastalih potrošnjom energije utvrđeno je sljedeće:

- prosječni specifični godišnji trošak $C'_{QH,del}$ za isporučenu toplinsku energiju za grijanje iznosi 6,91 EUR/m^{2}god,
- prosječni specifični trošak za utrošenu električnu energiju ($C'_{E,del}$) iznosi 1,41 EUR/m^{2}god,
- ukupan prosječni godišnji specifični trošak isporučene energije ($C'_{e,del}$) iznosi 8,32 EUR/m^{2}god,
- udio troškova toplinske energije u ukupnim troškovima energije iznosi oko 83% a udio troškova za električnu energiju iznosi oko 17%,
- troškovi za toplinsku energiju za grijanje ovise od potrošnje toplinske energije i jediničnog troška energenata za grijanje,
- troškovi za električnu energiju ovise od potrošnje električne energije i jediničnog troška električne energije,
- velika zastupljenost okolišno neprihvatljivih fosilnih goriva (lož ulje i ugalj) kao energenata za grijanje u oko 75% škola,
- najniže prosječne specifične godišnje troškove za grijanje imaju škole koje se griju na energent pelet koji iznose 2,51 EUR/ m^{2}god i
- najviše prosječne specifične godišnje troškove za grijanje imaju škole koje se griju daljinsko grijanje (13% škola iz uzorka) koji iznose 10,91 EUR/m^{2}god što je posljedica najvećeg stupnja stvarne potrošnje toplinske energije i načina obračuna bez mjerenja stvarne potrošnje.

Prethodno prikazani rezultati provedenog istraživanja ukazuju na jako loše energetske karakteristike postojećih školskih zgrada u FBiH te se u svrhu smanjenja toplinskih gubitaka prilikom izrade DEA predlažu mjere na poboljšanju energetske učinkovitosti građevinskih dijelova ovojnice, i to najčešće kroz toplinsku izolaciju vanjskih zidova, toplinsku izolaciju stropova prema tavanu, krovovima ili negrijanim prostorima i potpunu ili djelomičnu zamjenu vanjskih otvora.

Smanjenje troškova za grijanje moguće je postići smanjenjem potrošnje toplinske energije primjenom mjera za poboljšanje energetske učinkovitosti termotehničkih sustava grijanja kroz poboljšanje stupnja učinkovitosti sustava grijanja i/ili zamjenom energenta za grijanje.

Mjere za poboljšanje energetske učinkovitosti mogu se klasificirati u kategorije prema energetskom, ekonomskom i okolišnom doprinosu. U energetskom smislu navedeno utječe na smanjenje potreba za toplinskom energijom za grijanje (zbog smanjenja toplinskih gubitaka) te na smanjenje troškova za grijanje, odnosno smanjenja uporabnih troškova toplinske energije (ekonomski kriterij). Navedeno ima utjecaja i na smanjenje utjecaja na okoliš i smanjenje emisije štetnih plinova. U ovom radu ne će se analizirati niti ocjenjivati utjecaj mjera za poboljšanje energetske učinkovitosti.

U ovom poglavlju prikazan je postupak proračuna energetskih karakteristika zgrada koja se odnose na potrošnju toplinske energije školskih zgrada u FBiH iz uzorka. Pri tome su se koristile inženjerske metode temeljene na modeliranju i analizi pomoću fizikalnih zakona uz korištenje normativa kao što su ISO 16346 (norma koja definira procese za metodologiju proračuna) i ISO 13790 (norma za izračunavanje potrebne energije za grijanje). Ovakvi postupci proračuna potrošnje i troškova toplinske energije zahtijevaju veliku količinu ulaznih podataka pa su prikladni kada je investicijsko-tehnička dokumentacija dovoljno razrađena (ovakvi postupci se najčešće provode u fazi kad se izrađuje glavni projekt i vrši dokazivanje ispunjenja bitnih svojstava zgrada kao što je toplinska zaštita). Također, ovakvi postupci proračuna se provode i prilikom izrade detaljnih energetskih pregleda zgrada što je u ovom istraživanju iskorišteno za prikupljanje podataka o energetskim karakteristikama postojećih školskih zgrada u FBiH.

Međutim, kako bi se u inženjerskoj praksi još u ranijim preliminarnim fazama izrade projektne dokumentacije (u početnim inicijalnim fazama projektiranja prilikom analize ukupnih troškova životnog ciklusa zgrada u svrhu vrjednovanja varijantnih projektnih rješenja i donošenja investicijskih odluka) ili za potrebe upravljanja i održavanja postojećih zgrada moglo jednostavnije analizirati troškovi toplinske energije, potrebno je razvijati matematičke modele kojima se na temelju manjeg broja parametara ili karakteristika zgrada mogu s dovoljnom točnošću jednostavnije i brže izvršiti proračun toplinske energije i troškova toplinske energije zgrada.

5. Izrada i validacija modela procjene troškova toplinske energije školskih zgrada u FBiH

5.1 Definiranje hipoteze istraživanja

Često problem statističke analize ne uključuje određivanje izvorno nepoznatog parametra, već postoji unaprijed stvoreno mišljenje o vrijednosti parametra, tj. hipoteza [112]. Znanstvena hipoteza ovog istraživanja jeste da se neovisnim varijablama (karakteristikama zgrada) mogu procijeniti ovisne varijable odnosno troškovi toplinske energije školskih zgrada u FBiH.

Iz znanstvene hipoteze izvodi se statistička hipoteza koja se iskazuje na način da može biti vrjednovana statističko-analitičkim postupcima i predstavlja matematički izraz na kojem se temelji kalkulacija statističkog testa [26]. Testiranje statističke hipoteze je postupak donošenja odluke o prihvaćanju ili odbacivanju statističke hipoteze. Zadatak teorije testiranja statističkih hipoteza je razvoj određene metode kojima će se moći razlučiti značajna odstupanja od tolerantnih odstupanja. Definiraju se nul-hipoteza H_0 i alternativna hipoteza H_1. Pri tome znači da prihvatiti hipotezu H_0 istodobno znači odbaciti hipotezu H_1 i obratno odbaciti hipotezu H_0 istodobno znači prihvatiti hipotezu H_1 [91]. U praksi je uobičajeno da se odbacuje nul-hipoteza i prihvaća alternativa ako je $p<0,01$ (stroži kriterij), odnosno $p<0,05$ (blaži kriterij) [90].

Znanstvena hipoteza ovog istraživanja jeste da se neovisnim varijablama ili karakteristikama (godina izgradnje, korisna površina, površina ovojnice, volumen grijanog prostora, toplinske karakteristike građevinskih dijelova ovojnice, način i režim grijanja, učinkovitost sustava grijanja, energent koji se koristi za grijanje, klimatski podatci s obzirom na lokaciju zgrade) školskih zgrada kroz razvoj novih matematičkih modela mogu procijeniti ovisne varijable, odnosno troškovi toplinske energije školskih zgrada u FBiH.

U ovome radu postavljena je nul-hipoteza H_0 kako se neovisnim varijablama (karakteristikama zgrada) ne mogu procijeniti troškovi toplinske energije školskih zgrada u FBiH, odnosno alternativna hipoteza H_1 kako se neovisnim varijablama (karakteristikama zgrada) mogu predvidjeti troškovi toplinske energije školskih zgrada u FBiH.

5.2 Izbor mogućih varijabli

U poglavlju 4, na temelju prikupljenih i obrađenih podataka iz dokumenata detaljnih energetskih pregleda, izvršena je analiza energetskih karakteristika školskih zgrada u FBiH, potrošnje i troškova toplinske i električne energije koristeći deskriptivnu statistiku. Pri tome nije istraživana međusobna povezanost dvaju ili više karakteristika ili varijabli.

Svrha ovog istraživanja je analiza karakteristika (varijabli) školskih zgrada u FBiH iz uzorka i određivanje njihove povezanosti s troškovima toplinske energije. To znači da treba utvrditi koje sve moguće varijable imaju utjecaj na troškove toplinske energije i utvrditi njihovu međusobnu povezanost.

Veza između dviju varijabli može biti funkcionalna kada jednoj vrijednosti varijable odgovara točno određena vrijednost druge varijable i statistička (stohastička) kada jednoj vrijednosti varijable odgovara više vrijednosti druge varijable i koje u pravilu nisu toliko čvrsto povezane. Korelacijskom analizom ispituje se stupanj povezanosti između dviju ili više varijabli i ukoliko se utvrdi određeni stupanj povezanosti između varijabli onda se regresijskom ili višestrukoregresijskom analizom razvija analitički izraz ili model koji najbolje opisuje odnos između promatranih varijabli [89].

Regresijska metoda koristi se za utvrđivanje utjecaja čimbenika (neovisnih varijabli) na ovisnu varijablu. Odabir najbolje regresijske jednadžbe za procjenu zavisne varijable ovisi o odnosima između specifičnih čimbenika (neovisnih varijabli) i zavisne varijable. Također, alati za simulaciju i modeliranje kao što su ekspertni sustavi, neuronske mreže (*Neural Networks, NN*), nejasna logika (*Fuzzy Logic, FL*) i genetski algoritmi (*Genetic Algorthams, GA*) omogućavaju rješavanje problema predviđanja. Umjetne neuronske mreže (*Artificial Neural Networks, ANN*) su metode modeliranja podataka koje pokušavaju riješiti složene probleme formuliranjem odnosa podataka, međutim nisu u mogućnosti pružiti objašnjenje zbog svojstvenih tehnika "crne kutije" i ne postoji pojednostavljena jednadžba koja može preslikati varijable podataka. ANN kao pristup "crne kutije", gdje se model izrađuje i koristi bez objašnjenja onoga što je model naučio, je prikladan ako je glavni cilj samo primijeniti ANN za procjenu postojećih podataka [113].

S obzirom na to da je svrha ovog istraživanja utvrditi koje sve moguće varijable mogu imati utjecaj na troškove toplinske energije, utvrditi njihovu međusobnu povezanost i definirati matematičke modele procjene troškova toplinske energije, koristit će se regresijska analiza. Ona omogućava analizu varijabli (u odnosu na važnost, dostupnost i prikupljanje istih), definiranje odnosa između neovisnih i ovisnih varijabli i razvoj modela za predviđanje.

Postavlja se pitanje, odnosno potrebno je istražiti, koje neovisne varijable se mogu smatrati relevantnim za definiranje modela procjene troškova toplinske energije školskih zgrada u FBiH kao konačnog cilja ovog istraživanja. U 2. poglavlju ovog rada dan je prikaz faktora koji utječu na potrošnju toplinske energije, a indirektno i na troškove toplinske energije:

- namjena zgrade,
- razdoblje izgradnje,
- geometrijske karakteristike zgrade,

- sastav konstrukcije građevinskih dijelova ovojnice i toplinska izolacija,
- klimatski uvjeti,
- ponašanje korisnika,
- režim i broj sati rada i
- efikasnost sustava grijanja, održavanje i upravljanje nad istim.

U istraživanju Gaitani i sur. analiziran je uzorak od 1100 škola u Grčkoj gdje su prikupljeni podatci iz energetskih pregleda škola na temelju čega je definirano sedam varijabli koje utječu na toplinske potrebe zgrade: grijana površina (m^2), starost zgrade (godine), izolacija zgrade, broj učionica, broj učenika, broj radnih sati dnevno škole i starost sustava grijanja (godine) [114]. Kada su u pitanju postojeće zgrade i energetska obnova istih, pregledom empirijskih studija radi utvrđivanja najutjecajnijih čimbenika koji predstavljaju prepreke i pokretače energetski učinkovite adaptacije zgrada definirano je pet skupina [115]:

- tehnički čimbenici ili karakteristike zgrade kao što su dob i vijek trajanja građevinskih dijelova, proširenje zgrade i prostora i poboljšanja toplinske ugodnosti definirani su kao ključni energetski učinkoviti poticaji u brojnim studijama,
- ekonomski čimbenici u većini empirijskih studija pokazuje da se ljudi mogu obeshrabriti u energetski učinkovitim preuređivanjima zbog visokih početnih troškova ulaganja i nedostatka financijskih sredstava,
- socijalno-ekonomske karakteristike uključuju dohodak ispitanika, dob i obrazovanje kao čimbenike koji su presudni u donošenju odluka vezanih za energetsku obnovu,
- čimbenici ponašanja kao što su ekološka svijest, znanje i stavovi najčešće su prepoznati kao važni pokretači i
- nedostatak informacija o trenutnoj potrošnji energije, tehnološkim opcijama i potencijalu za uštedu energije također je dokumentiran kao značajna prepreka.

Regresija je statistička metoda koja pokušava utvrditi snagu i karakter odnosa između jedne ovisne varijable i niza neovisnih varijabli. Izbor neovisnih varijabli osnovni je problem pri svakoj regresijskoj analizi pri čemu se nastoji zadovoljiti više kriterija kao što su jednostavnost modela, zatim da neovisne varijable što bolje opisuju model i da u modelu budu uključene samo bitne varijable koje daju najmanju pogrešku [26]. Postupni regresijski modeli puno su uspješniji kada postupak započinje s 5 bitnih (*true*) varijabli i 5 nebitnih (*nuisance*) varijabli nego s 5 bitnih varijabli i stotinama nebitnih varijabli [116].

U statističkoj literaturi inputi se često nazivaju prediktorima, a klasičnije neovisne varijable. Izlazi se nazivaju odgovori (outputi) ili klasično ovisne varijable. Skup varijabli koje se mogu označiti kao ulazi, koje se mjere ili unaprijed postavljaju, imaju određeni utjecaj na jedan ili više rezultata. Cilj je koristiti ulaze za predviđanje vrijednosti izlaza [117].

Cilj bilo kojeg projekta povezanog s podatcima je izvući informacije ili znanje iz dostupnih podataka i izvesti značajne zaključke. Od iznimne je važnosti uzeti u obzir samo važne varijable kako bi se zadatak učinkovito izvršio i dobio pouzdan ishod. Važnost varijable predstavlja vrijednost koja kvantificira intenzitet povezanosti između rezultata modela i neovisne varijable pojedinačno ili kao skupa. Potrebno je provesti analizu varijabilne važnosti kako bi se dobili precizni pouzdani rezultati modeliranja. Postupak odabira varijabli može se shvatiti kao postupak odabira podskupine najvažnijih varijabli koji optimizira ciljnu funkciju i minimizira rizik. Neki od razloga za korištenje postupka odabira ili selektiranja varijabli [118]:

- Odabir varijabli ima značajnu prednost jer omogućava brži proračun, što dovodi do smanjenog vremena i smanjenih troškova koji su uključeni u proces,
- Igra ključnu ulogu u pročišćavanju i jačanju performansi modela odabirom najznačajnijih varijabli koje doprinose prediktivnoj točnosti modela koji se proučava i
- Zadržavajući samo značajne varijable u modelu, čini analizu razumljivijom kako bi se steklo znanje o procesu i pomoglo u donošenju važnih odluka brzo i pouzdano.

S obzirom na sve faktore koji imaju utjecaj na potrošnju i troškove toplinske energije, kao i dostupne podatke u ovom istraživanju iz dokumenata detaljnih energetskih pregleda o energetskim karakteristikama školskih zgrada u FBiH i potrošnje energije koji su posebno analizirani u poglavlju 4. u nastavku su analizirane neovisne i ovisne varijable koje mogu ući u postupak razvoja regresijskih modela.

U ovom istraživanju neovisne varijable ili inputi će se označavati s X_i i one predstavljaju karakteristike školskih zgrada u FBiH. Ovisne varijable ili outputi će se označavati s Y_i i one predstavljaju očekivane vrijednosti ovisne varijable s obzirom na ulazne vrijednosti neovisne varijable. U tablici 5.1 je dan popis 28 mogućih neovisnih varijabli (od kojih su neke osnovne, a neke izvedene) koje će se u idućim koracima istraživati. Izvedene varijable nastaju kada se osnovne varijable podijele s nekom karakteristikom zgrade (npr. izvedena varijabla je broj korisnika u odnosu na korisnu površinu (A_k) koja je određena kao odnos ukupnog broja korisnika zgrade i korisne površine zgrade).

Tablica 5.1 Popis mogućih neovisnih varijabli za razvoj regresijskih modela procjene troškova toplinske energije školskih zgrada u FBiH iz uzorka

R. br.	Kategorija	Opis neovisnih varijabli	Jedinica mjere	Oznaka
1.	Klimatski uvjeti	Broj stupanj dana grijanja - SDG	°C·dana	X1
2.		Srednja temperatura u sezoni grijanja (izvedena iz srednjih mjesečnih temperatura u sezoni grijanja)	°C	X2
3.	Korisnici	Ukupan broj korisnika (djelatnici i učenici)	broj korisnika	X3
4.		Broj korisnika u odnosu na korisnu površinu (A_k)	broj korisnika/m^2	X4
5.	Opći podatci	Godina izgradnje - GI	god	X5
6.		Postojanje školske dvorane (DA=1/NE=0)	-	X6
7.	Geometrijski podatci	Korisna površina - A_k	m^2	X7
8.		Volumen grijanog dijela zgrade - V_e	m^3	X8
9.		Površina o ovojnice grijanog dijela zgrade - A	m^2	X9
10.		Faktor oblika $f=A/A_k$	-	X10
11.		Faktor kompaktnosti $f_o=A/V_e$	m^{-1}	X11
12.		Površina zidova ovojnice – A_Z	m^2	X12
13.		Površina podova ovojnice – A_P	m^2	X13
14.		Površina stropova ovojnice – A_S	m^2	X14
15.		Površina otvora ovojnice – A_O	m^2	X15
16.	Toplinske karakteristike	U - vrijednost za zidove – U_Z	W/m^{2}K	X16
17.		U - vrijednost za podove – U_P	W/m^{2}K	X17
18.		U - vrijednost za stropove – U_S	W/m^{2}K	X18
19.		U - vrijednost za otvore – U_O	W/m^{2}K	X19
20.		U - vrijednost ovojnice – U	W/m^{2}K	X20
21.		Koeficijent transmisijske izmjene topline - H_{tr}	W/K	X21
22.		Koeficijent transmisijske izmjene topline po površini ovojnice (A) - $H'_{tr,adj}$	W/ m^{2}K	X22
23.		Ukupan koeficijent izmjene topline - H	W/K	X23
24.		Ukupan koeficijent izmjene topline po površini ovojnice (A) - H'	W/ m2K	X24
25.	Energent, učinkovitost sustava grijanja i režim rada	Vrsta energenta (ugljen i drvo - 1, pelet - 2, lož ulje (LU) i ekstra lako lož ulje (ELLU) - 3, daljinsko grijanje (DG) - 4, prirodni plin - 5, i električna energija - 6)	-	X25
26.		Učinkovitost sustava grijanja - η_{sys}	-	X26
27.		Dnevno sati rada sustava grijanja	sati	X27
28.		Jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji - $UC_{QH,del}$	EUR/kWh	X28

U nastavku su dani komentari u odnosu na dostupnost i određivanje vrijednosti opisanih neovisnih varijabli u tablici 5.1. Općenito se može zaključiti kako su za prikupljanje i određivanje vrijednosti neovisnih varijabli potrebna određena stručna znanja osobe koja ih prikuplja i koristi.

Varijabla X1 (broj stupanj dana grijanja – SDG) predstavlja jedan parametar koji karakterizira klimatske uvjete koji utječu na toplinske potrebe. Relativno se lako odredi prema lokaciji i prilogu Pravilniku o minimalnim zahtjevima za energetskim značajkama zgrada.

Varijabla X2 (srednja temperatura u sezoni grijanja) predstavlja također jedan od parametara koji karakterizira klimatske uvjete i teže ju je procijeniti u odnosu na varijablu X1, a za ovo istraživanje ova neovisna varijabla je izvedena iz srednjih mjesečnih temperatura u sezoni grijanja.

Varijabla X3 i X4 se odnose se na okupiranost prostora i predstavlja ukupan broj korisnika (djelatnici i učenici koji pohađaju škole), odnosno broj korisnika u odnosu na korisnu površinu A_k.

Od općih i geometrijskih podataka u popis mogućih neovisnih varijabli uključene su slijedeće:

- Varijabla X5 određuje razdoblje izgradnje i starost zgrade. Pretpostavlja se da starost zgrade utječe na potrošnju i troškove toplinske energije. Lako se određuje.
- Varijabla X6 definira postojanje školske dvorane.
- Varijabla X7 predstavlja korisnu površinu (A_k). Pretpostavlja se da veličina zgrade utječe na ukupnu godišnju potrošnju i troškove energije. Podatak koji je uglavnom poznat.
- Varijabla X8 predstavlja volumen grijanog dijela zgrade (V_e). Ovaj podatak uglavnom nije poznat ali ga je moguće izračunati.
- Varijabla X9 predstavlja površinu ovojnice (A) grijanog dijela zgrade. Pretpostavlja se da veličina površine ovojnice zgrade utječe na ukupnu potrošnju i troškove energije. Ovaj podatak uglavnom nije poznat ali ga je moguće izračunati.
- Varijabla X10 predstavlja faktor oblika (f) koji se određuje kao odnos površine ovojnice (A) i korisne površine (A_k). Podatak koji je nije poznat, ali se može izračunati.
- Varijabla X11 predstavlja faktor kompaktnosti (f_o) koji se određuje kao odnos površine ovojnice (A) i zapremine grijanog zraka (V_e). Pretpostavlja se da kompaktnije zgrade (koje imaju manju vrijednost faktora kompaktnosti) imaju manju potrošnju energije. Podatak koji je nije poznat ali se može izračunati.

- Varijable X12, X13, X14 i X15 predstavljaju površine građevinskih dijelova ovojnice zgrade svrstane u 4 grupe, i to zidovi, podovi, stropovi i otvori. Podatci koji nisu poznati i teže ih je za odrediti (potrebno ih je izračunati).

Varijable X16, X17, X18, X19 i X20 predstavljaju prosječne toplinske karakteristike građevinskih dijelova ovojnice izražene preko koeficijenata prolaska topline, U-vrijednosti (W/m^{2}K). Pretpostavlja se da zgrade koje imaju veće U-vrijednosti imaju i veću potrošnju energije. Podatci koji nisu poznati, ali se mogu procijeniti prema razdoblju izgradnje koristeći stručnu literaturu ili dokument Tipologija javnih zgrada u BiH u kojemu se nalaze prosječne U-vrijednosti građevinskih dijelova ovojnice u odnosu na razdoblja izgradnje kao što je prikazano u tablici 3.8.

Varijable X21, X22, X23 i X24 predstavljaju koeficijente ukupnih transmisijskih i ventilacijskih gubitaka. Određuju se na temelju površina građevinskih dijelova ovojnice, njihovih U-vrijednosti, izmjena broja zraka, infiltracije zraka i drugih parametara. Podatci koji nisu poznati i jako teško ih je odrediti osobama koje nisu stručne, osim u slučajevima kada se raspolaže određenom tehničkom dokumentacijom ili dokumentom detaljnog energetskog pregleda.

Varijable X25, X26 i X27 odnose se na energent koji se koristi za grijanje, sustav grijanja (njegovu učinkovitost) i režim rada (broj sati dnevno grijanja). Podatci koji su poznati ili se mogu procijeniti (za učinkovitost sustava grijanja).

Varijabla X28 je funkcija jedinične cijene na tržištu energenta koji se koristi za grijanje i njegove ogrjevne vrijednosti (podatci koji se mogu pronaći u stručnoj literaturi). Podatak koji se jednostavno može izračunati.

Gore navedene neovisne varijable predstavljaju bazu za razvijanje regresijskih modela. Korelacijskom analizom odredit će se koje su neovisne varijable u korelaciji s ovisnim varijablama, te koje su statistički značajne. U poglavlju 4.3 utvrđeno je da stvarne vrijednosti ukupne godišnje isporučene toplinske energije za grijanje ($Q_{H,del}$) imaju veliku disperziju (rasipanje vrijednosti), odnosno da stvarne vrijednosti potrošnje toplinske energije nisu u skladu s potrebama nego ovise o drugim varijablama koje se ne mogu definirati (potrošnja toplinske energije ovisi o raspoloživim novčanim sredstvima za nabavku energenata za grijanje).

Nadalje, analiza u poglavlju 4.5 pokazuje kako je stvarna potrošnja isporučene toplinske energije neznatno povezana (korelirana) s ključnim karakteristikama kao što je godina izgradnje (starost zgrade) i U-vrijednost ovojnice kao parametra toplinskih gubitaka. Kako u ovom istraživanju postoje podatci o proračunskoj potrošnji toplinske energije (proračunske vrijednosti odnose se na potrošnju toplinske energije prema stvarnim potrebama koje su izračunate sukladno propisima i normama) i troškovima

toplinske energije u korelacijskoj analizi isti će se uzeti kao ovisne varijable za razvoj regresijskih modela procjene troškova toplinske energije.

U tablici 5.2 dan je popis ovisnih varijabli. Ovisne varijable uključuju stvarne i proračunske ukupne i specifične troškove toplinske energije ali su u razvoj regresijskih modela uključene i ovisne varijable za stvarne i proračunske potrošnje (potrebne i isporučene) toplinske energije preko kojih se mogu odrediti stvarni i proračunski troškovi toplinske energije.

Tablica 5.2 Popis mogućih ovisnih varijabli za razvoj regresijskih modela procjene troškova toplinske energije školskih zgrada u FBiH iz uzorka

R. br.	Opis ovisnih varijabli	Jedinica mjere	Oznaka
1.	Godišnja stvarna isporučena toplinska energija za grijanje - $Q_{H,del}$	kWh/god	Y1
2.	Godišnji stvarni trošak isporučene toplinske energije - $C_{QH,del}$	EUR/god	Y2
3.	Godišnja proračunska potrebna toplinska energija za grijanje - $Q_{H,nd,cal}$	kWh/god	Y0,cal
4.	Godišnja proračunska specifična potrebna toplinska energija za grijanje - $Q'_{H,nd,cal}$	kWh/m^{2}god	Y0,cal,spec
5.	Godišnja proračunska isporučena toplinska energija za grijanje - $Q_{H,del,cal}$	kWh/god	Y1,cal
6.	Godišnja proračunska specifična isporučena toplinska energija za grijanje - $Q'_{H,del,cal}$	kWh/m^{2}god	Y1,cal,spec
7.	Godišnji proračunski trošak isporučene toplinske energije - $C_{QH,del,cal}$	EUR/god	Y2,cal
8.	Godišnji specifični proračunski trošak isporučene toplinske energije - $C'_{QH,del,cal}$	EUR/m^{2}god	Y2,cal,spec

Ukupne stvarne godišnje troškove isporučene toplinske energije ($C_{QH,del}$) moguće je izračunati preko ukupne godišnje isporučene toplinske energija za grijanje ($Q_{H,del}$) i jediničnog troška energenata ($UC_{QH,del}$) za grijanje prema sljedećem izrazu:

$$C_{QH,del} = Q_{H,del} \cdot UC_{QH,del} \left[EUR / god \right] \tag{5.1}$$

gdje su:

- $Q_{H,del}$ godišnja isporučena toplinska energija za grijanje (kWh/god) i

- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Ukupne godišnje proračunske troškove za isporučenu toplinsku energiju ($C_{QH,del,cal}$) moguće je izračunati preko sljedećih izraza:

$$C_{QH,del,cal} = \frac{Q_{\mathrm{H,nd,cal}}}{\eta_{\mathrm{sys}}} \cdot UC_{QH,del} \left[EUR / god \right] \tag{5.2}$$

$$C_{QH,del,cal} = \frac{Q'_{\mathrm{H,nd,cal}}}{\eta_{\mathrm{sys}}} \cdot A_K \cdot UC_{QH,del} \left[EUR / god \right] \tag{5.3}$$

$$C_{QH,del,cal} = Q_{H,del,cal} \cdot UC_{QH,del} \left[EUR / god \right] \tag{5.4}$$

$$C_{QH,del,cal} = Q'_{H,del,cal} \cdot A_K \cdot UC_{QH,del} \left[EUR / god \right] \tag{5.5}$$

$$C_{QH,del,cal} = C'_{QH,del,cal} \cdot A_K \left[EUR / god \right] \tag{5.6}$$

gdje su:

- $Q_{H,nd,cal}$ godišnja proračunska potrebna toplinska energija za grijanje (kWh/god),
- $Q'_{H,nd,cal}$ godišnja proračunska specifična potrebna toplinska energija za grijanje (kWh/m^{2}god),
- $Q_{H,del,cal}$ godišnja proračunska isporučena toplinska energija za grijanje (kWh/god),
- $Q'_{H,del,cal}$ godišnja proračunska specifična isporučena toplinska energija za grijanje (kWh/m^{2}god),
- $C'_{QH,del,cal}$ godišnji proračunski specifični trošak isporučene toplinske energije (EUR/m^{2}god),
- A_K korisna površina zgrade,
- η_{sys} učinkovitost sustava grijanja i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Preko ovisne varijable Y2 i izraza 5.1 moguće je indirektno izračunati ukupne stvarne godišnje troškove isporučene toplinske energije ($C_{QH,del}$) označene kao varijabla Y1, a preko neovisnih varijabli Y0,cal, Y0,cal,spec, Y1,cal, Y1,cal,spec i Y2,cal,spec i izraza od 5.2 do 5.6 moguće je indirektno izračunati ukupne godišnje proračunske troškove isporučene toplinske energije ($C_{QH,del,cal}$) označene kao varijabla Y2,cal. Zbog navedenog za sve ovisne varijable prikazane u tablici 5.2 izvršit će se razvoj regresijskih modela te će se isti ocjenjivati koristeći statističke metode u funkciji ukupnih stvarnih ili proračunskih godišnjih troškova toplinske energije.

5.3 Određivanje seta podataka za razvoj i validaciju regresijskih modela

Za bilo kakvu regresiju važno je uzeti u obzir ponovljivost osnovnih podataka. Bi li slična regresija provedena na različitim podatcima dala slične rezultate? Idealno se ovo pitanje rješava izvođenjem iste regresije na drugom neovisnom skupu podataka. To se naziva vanjska provjera valjanosti. U mnogim slučajevima dodatni, neovisni podatci jednostavno nisu dostupni. Tada je alternativni pristup nasumce podijeliti izvorni skup podataka u dva podskupa i usporediti rezultate regresije za dva podskupa. To se naziva interna provjera validnosti [119].

Slabosti modela mogu se otkriti pogoršanjem prilagođenosti modela korištenjem svježih podataka. Stoga je razumno pružiti dio dostupnih podataka za testiranje procijenjenog modela. U posljednje vrijeme uzorak se dijeli na 2 dijela, i to podatci za trening (*training data*) odnosno razvoj modela i podatci za validaciju (*validation data*). Uvijek je dobra ideja testirati model s novim, nekorištenim podatcima za izradu modela. Međutim, odabir modela s podatcima korištenim u uzorku i ispitivanje izvan uzorka ne jamči da će se odabrati najbolji model. Otkrivanje modela koji odgovara i podatcima iz uzorka (*training data*) i podatcima izvan uzorka (*validation data*) samo je još jedan oblik istraživanja podataka. Umjesto da se otkrije model koji odgovara polovici podataka, otkriva se model koji odgovara svim podatcima. To ne rješava temeljni problem, a to je da se ne može očekivati da modeli koji su odabrani samo da odgovaraju podatcima, bilo polovina podataka ili svi podatci, odgovaraju i novim podatcima [116].

Osim podjele osnovnog uzorka na podatke za razvoj modela (*training data*) i podatke za validaciju (*validation data*) postoji i podjela u tri podskupine, i to skup podataka za razvoj (*training set*), skup podataka koji se koristi za provjeru valjanosti ili validnosti modela (*validation set*) i testni skup (*test set*) koji se koristi za nepristranu procjenu konačnog modela. Uobičajeni omjeri koji se koriste su u podjeli osnovnog uzorka (training/validation/test) su 70/15/15%, 80/10/10% i 60/20/20% [120]. Kompromisi kod izbora omjera su sljedeći [120]:

- Više podataka je dobro za razvoj modela, jer to znači da model vidi više primjera i stoga se nadamo da će pronaći bolje rješenje. S druge strane, ako je korišten mali skup podataka za razvoj modela, model ne će moći naučiti opća načela i imat će loše rezultate prilikom provjere valjanosti ili testa.
- Dobro je imati više podataka za provjeru valjanosti jer pomaže u donošenju bolje odluke o tome koji je model "najbolji". Ako nema dovoljno podataka za provjeru valjanosti, tada će biti teško procijeniti koji je model ''najbolji".
- Više testnih podataka daje bolji uvid u to koliko dobro model generalizira neviđene podatke. Ako nema dovoljno podataka za testiranje, konačna procjena generalizacijske sposobnosti modela možda ne će biti točna.

Postavlja se slijedeće pitanje? Ako postoji set za razvoj modela i set za provjeru valjanosti, zašto je potreban i testni set? Test set je važan korak odabira ''najboljeg'' modela jer provjera valjanosti može prikazivati prekomjerno (*overfitting*) dobre rezultate modela. Da bi se dobila realna i pouzdana procjena koliko će dobro raditi "najbolji'' model na podatcima koje nikada prije nije vidio koristi se testni set ili skup. Koraci u izboru skupova podataka za razvoj regresijskih modela su sljedeći i prikazani su na slici 5.1 [120]:

- nasumični odabir svakog modela,
- razvoj svakog modela na setu za razvoj modela,
- procjena svakog razvijenog modela na setu za validaciju,
- odabir modela s najboljim rezultatima prema setu za validaciju i,
- ocjena odabranog modela na setu za testiranje.

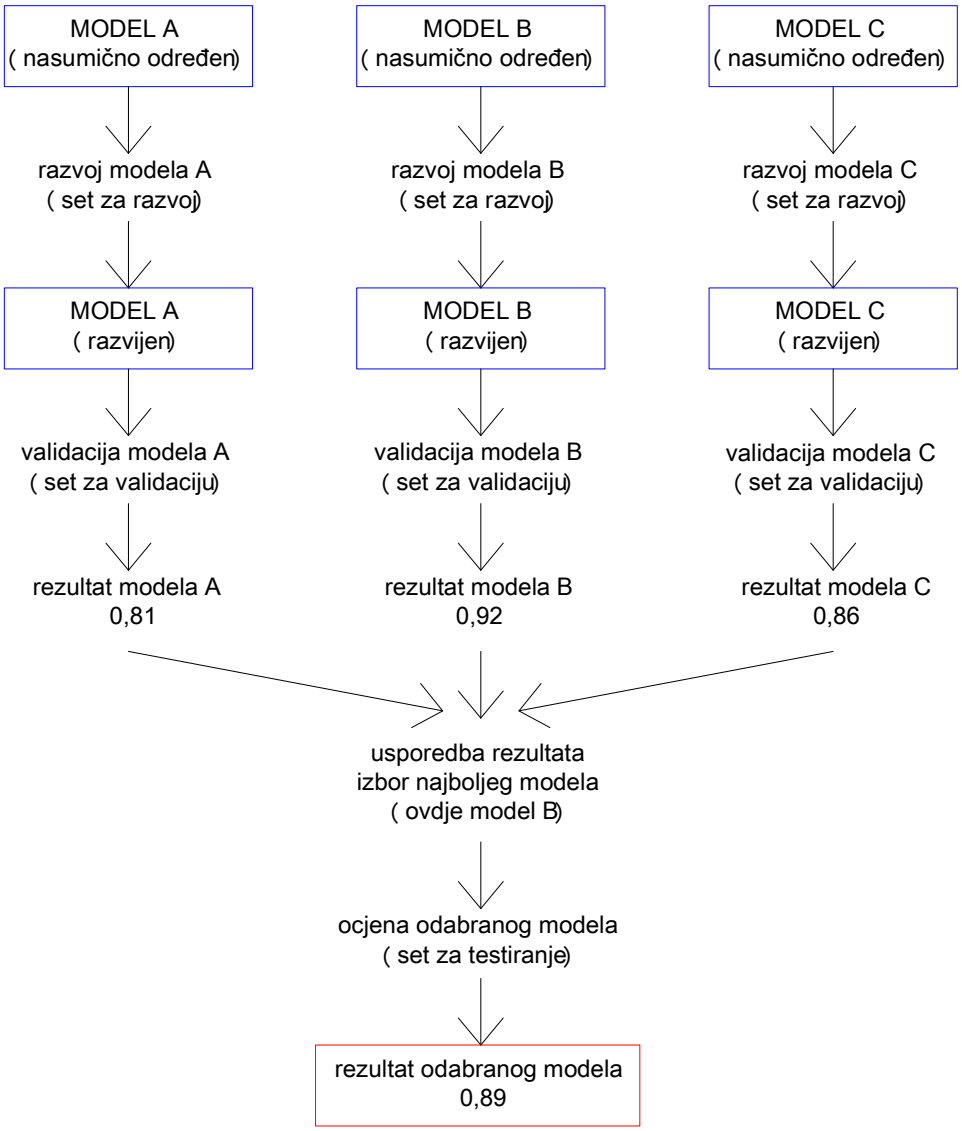

Slika 5.1 Koraci u razvoju regresijskih modela [120]

Na slici 5.1 dan je prikaz koraka u razvoju regresijskih modela koristeći tri seta podataka i to set za razvoj, set za validaciju i set za testiranje modela. Brojevi 0,81, 0,92 i 0,86 pokazuju ukupan rezultat procjene pogreške predviđanja pojedinačnih nasumično odabranih modela A, B i C nakon validacije istih, dok broj 0,89 predstavlja konačan rezultat procjene pogreške nakon testiranja najbolje ocijenjenog modela B. Ovakav postupak razvoja regresijskih modela zahtijeva veliki broj kombinacija, posebice u situacijama kad se razvijaju regresijski modeli za više ovisnih varijabli. Pregledom literature utvrđeno je kako se u razvoju regresijskih modela može osnovni skup podataka podijeliti u 2 dijela, i to set za razvoj i set za validaciju ili testiranje [113, 121, 122]. U nastavku su dani primjeri podjele ukupnog seta podataka na dva seta (set za razvoj i set za validaciju).

U razvoju statističkog modela za predviđanje potrošnje energije za 1,1 milijun zgrada u New Yorku korišteni su podatci o fizičkim, prostornim i energetskim karakteristikama prikupljeni iz 23.000 zgrada.

Pristup izradi modela i izračunavanju pogreške modela napravljen je na način da je osnovni očišćeni skup podataka nasumce podijeljen na dva dijela. Prvi dio seta sadrži 70% uzorka i služi za razvijanje modela. Drugi dio seta podataka od 30% naziva se test ili ispitni set, koji se naziva i set zadržavanja, i ne koristi se za razvoj modela nego za izračunavanje pogreške predviđanja modela. Ovaj postupak daje pouzdaniju procjenu pogreške predviđanja izvan uzorka [122].

Na sličan način prilikom izrade modela predviđanja potrošnje energije višestambenih zgrada pomoću regresije vektora potpore izvršena je podjela osnovnog seta u set za razvijanje modela (trening set) koji iznosi 70% i set provjere valjanosti koji iznosi 30% osnovnog seta [121].

Na izvedbi studije čiji je cilj bio usporedba učinaka korištenih metoda procjene (višestruka regresija i ANN-ovi modeli) troškova uporabe i održavanja korišten je katalog 20 građevinskih projekata koji je podijeljen u dva seta. Jedan skup sastoji se od 17 projekata koji se koriste za razvoj modela, a 3 projekta koriste se za provjeru valjanosti modela [113].

S obzirom na velik broj neovisnih i ovisnih varijabli i njihovih međusobnih kombinacija, a u svrhu razvoja regresijskih modela kojim će se opisati odnos između neovisnih i ovisnih varijabli, u ovom radu izvršeno je razdvajanje osnovnog uzorka na dva seta podataka, i to na set za razvoj modela (*training set*) koji će služiti za izradu modela i set koji će služiti samo za validaciju (*validation set*), odnosno procjenu pogreške predviđanja odabranih modela.

U razdoblju izgradnje poslije 2010. godine postoji samo 1 školska zgrada koja se izdvaja iz osnovnog uzorka tako da se regresijski modeli za procjenu troškova toplinske energije školskih zgrada u FBiH ne će razvijati za razdoblje poslije 2010. godine, nego samo do 2010. godine tako da je osnovni uzorak (set podataka) reduciran na 184 škole.

Podjela ukupnog seta podataka iz osnovnog uzorka na set za razvoj modela i set za validaciju modela izvršena je nasumičnim (random) postupkom. Razdvajanje osnovnog seta nasumičnim postupkom (korištenjem MS Excel-a i naredbe za nasumični odabir) izvršeno je iterativnim postupkom na način da je iz osnovnog uzorka od 184 školske zgrade izdvojen set za validaciju po principu najmanje 20% školskih zgrada iz svakog razdoblja izgradnje i svake klimatske regije kako bi se osigurala jednaka zastupljenost. U slučajevima gdje nije zadovoljen prethodni uvjet u set za validaciju modela izdvajana je minimalno 1 škola. U tablici 5.3 dan je broj školskih zgrada u FBiH koje su nasumično odabrane za set za validaciju zajedno s njihovim šiframa a preostali broj (u odnosu na ukupni broj školskih zgrada po razdobljima izgradnje i klimatskim regijama) se odnosi na set koji služi za razvoj modela.

Tablica 5.3 Podjela broja školskih zgrada u FBiH iz uzorka u odnosu na set za razvoj i validaciju regresijskih modela

ŠKOLSKE ZGRADE U FBIH IZ UZORKA		Broj školskih zgrada u FBiH iz uzorka	Broj školskih zgrada u FBiH za set za validaciju	Šifra nasumično odabranih školskih zgrada u FBiH a za set za validaciju	Broj školskih zgrada u FBiH za razvoj modela
do 1945	FBiH	14	3	-	11
	RS FBiH	10	2	KS-SAR-25, ZDK-KAK-02	8
	RJ FBiH	4	1	ZHK-LJUB-02	3
od 1946 do 1965	FBiH	53	11	-	42
	RS FBiH	40	8	KS-SAR-05, ZDK-VIS-01, ZDK-ZAV-03, USK-KLJU-02, KS-SAR-09, PK-ORA-01, TK-LUK-02, ZHK-POS-04	32
	RJ FBiH	13	3	HNK-STO-01, HNK-MOS-06, ZHK-GRU-05	10
od 1966 do 1973	FBiH	36	8	-	28
	RS FBiH	28	6	USK-SM-01, TK-TUZ-01, KS-SAR-11, SBK-NT-01, ZDK-KAK-01, ZHK-POS-05	22
	RJ FBiH	8	2	ZHK-SB-01, HNK-MOS-01	6
od 1974 do 1987	FBiH	73	14	-	59
	RS FBiH	56	11	ZDK-TES-05, TK-CEL-02, USK-VK-03, USK-CAZ-01, KS-SAR-19, ZDK-BRE-02, SBK-DF-01, KS-SAR-01, USK-BIH-03, TK-SRE-03, ZDK-USO-02	45
	RJ FBiH	17	3	ZHK-SB-02, HNK-MOS-05, HNK-MOS-07	14
od 1988 do 2009	FBiH	8	2	-	6
	RS FBiH	4	1	ZDK-USO-01	3
	RJ FBiH	4	1	HNK-MOS-19	3
od 2010	FBiH	0	0	-	0
	RS FBiH	0	0	-	0
	RJ FBiH	0	0	-	0
UKUPNO	FBiH	184	38	-	146
	RS FBiH	138	28	-	110
	RJ FBiH	46	10	-	36

Ukupan broj školskih zgrada u FBiH iz uzorka za razvoj (*training set*) regresijskih modela iznosi 146 što predstavlja 79,3% u odnosu na osnovni reducirani uzorak (184). Ukupan broj školskih zgrada u FBiH iz uzorka za validaciju (*validation set*) regresijskih modela iznosi 38 što predstavlja 20,7% u odnosu na osnovni reducirani uzorak. Istraživanja pokazuju kako se prilikom razdvajanja osnovnog seta na set za razvoj u odnosu na set za validaciju (*training set/validation set*) mogu koristiti različiti omjeri kao 92/8% [123], 90/10% [124], 85/15% [113, 125], 80/20% [120], 75/25% [124] i 70/30% [121, 122]. Može se zaključiti kako odabrani omjer razdvajanja od 79/21% za ovo istraživanje uklapa u navedene primjere.

5.4 Korelacijska analiza

Povećanje dostupnosti velike količine podataka o energetskim karakteristikama zgrada omogućilo je razvoj metodologija odozgo prema dolje za analizu energetskih karakteristika zgrada. Ove se metodologije koriste statističkim tehnikama za predviđanje i procjenu energetskih karakteristika na temelju postojećih skupova podataka više zgrada. Većina statističkih modela koristi se nekom vrstom regresije za modeliranje i objašnjenje energetskih karakteristika zgrada [31].

Dovoljno izmjerenih podataka neophodno je za predviđanje i upravljanje svojstvima zgrade. Kada se razvija model, nedostaci u procesu prikupljanja podataka općenito znače da će nedostajati važne informacije. Mali skupovi podataka ne pružaju dovoljno informacija, što znači da se model može savršeno uvježbati, a izlazi mogu mapirati s izuzetno velikom točnošću, ali samo na promatranom skupu podataka. Osiguravanje dovoljnih podataka modelu omogućava otkrivanje opsežnijih pravila mapiranja i povećanja sposobnosti generalizacije modela [126].

Korelacija je promjena između dvije varijable koje idu jedna uz drugu. Drugim riječima, ako se s promjenom jedne varijable istovremeno mijenja i druga varijabla, tada se kaže da su dvije varijable u korelaciji. Ta sklonost istodobnoj varijaciji dviju varijabli naziva se korelacijom i ukazuje na neku vrstu odnosa između njih. Pearsonov koeficijent korelacije najčešće se koristi za mjerenje korelacije u statistici [118].

Teorija i iskustvo često daju samo općenite upute o tome koju bi skupinu varijabli kandidata trebalo uključiti u regresijski model. Stvarni skup neovisnih varijabli korištenih u konačnom regresijskom modelu mora se odrediti analizom podataka. Određivanje ovog podskupa naziva se problemom odabira varijabli. Pronalaženje ovog podskupa regresornih (neovisnih) varijabli uključuje dva suprotna cilja. Prvo, želi se da regresijski model bude što cjelovitiji i realniji. Želi se uključi svaki regresor koji je čak i daljinski povezan s zavisnom varijablom. Drugo, želi se uključiti što manje varijabli jer svaki nebitni regresor smanjuje preciznost procijenjenih koeficijenata i predviđenih vrijednosti. Također, prisutnost dodatnih varijabli povećava složenost prikupljanja podataka i održavanja modela. Cilj odabira varijabli je postići ravnotežu između jednostavnosti (što manje regresora) i prilagodbe (koliko god regresa treba) [127].

Manji model s manje kovarijacija ima dvije prednosti. Može dati bolja predviđanja od velikog modela i štedljiviji je (jednostavniji). Općenito, kako se dodaje više varijabli regresiji, pristranost predviđanja se smanjuje, a varijanca povećava. Premalo kovarijanti daje visoku pristranost (*underfitting*), a previše kovarijanti daje velike varijance (*overfitting*). Dobra predviđanja rezultat su postizanja dobre ravnoteže između pristranosti i varijance [128].

Nulta ili početna korelacija je mjera koja određuje veličinu bivarijatnog odnosa između neovisne i ovisne varijable, ne uzimajući u obzir doprinose ostalih varijabli u regresijskoj jednadžbi. Koristi se koeficijent korelacije (r) koji opisuje u kojoj mjeri su dvije varijable povezane. U slučaju kada su neovisne varijable nekorelirane, korelacije nultog reda ekvivalentne su beta regresijskim koeficijentima i dovoljne su za rangiranje neovisnih varijabli. Ova je mjera jedina mjera koja može kvantificirati koliko se varijance izravno dijeli između neovisne i ovisne varijable, a da na nju ne utječe zajednička varijanca između neovisnih varijabli [129].

Ovisna varijabla ne bi trebala biti funkcija njihovih vlastitih prethodnih vrijednosti (autokorelacija). Nezavisne varijable ne bi trebale biti međusobno povezane na što ukazuje multikolinearnost [119].

U praksi se statistička značajnost koeficijenta korelacije procjenjuje na razini značajnosti 1% ili 5% (p<0,01 ili p<0,05 koji predstavlja gornju granicu). Statistička značajnost (p) od 1% ili 5% predstavlja vjerojatnost da se drugim mjerenjima ne će dobiti razlika veća od 1% ili 5%. Vrijednost Pearsonovog koeficijenata linearne korelacije (r) određuje se prema sljedećem izrazu [89]:

$$r = \frac{\sum_{i=1}^{n} x_i y_i - N \times \overline{X} \times \overline{Y}}{\sqrt{(\sum_{i=1}^{n} x_i^2 - N\overline{X}^2)(\sum_{i=1}^{n} y_i^2 - N\overline{Y}^2)}} \tag{5.7}$$

gdje su:

- x_i, y_i stvarne vrijednosti neovisne i ovisne varijable,
- $\overline{X}$, $\overline{Y}$ prosječna vrijednost neovisne i ovisne varijable,
- N ukupan broj parova.

Vrijednosti koeficijenta korelacije od 0 do 0,25 ili od 0 do –0,25 upućuju kako nema povezanosti, dok vrijednosti od 0,25 do 0,50 ili od –0,25 do –0,50 upućuju na slabu povezanost među varijablama. Vrijednosti od 0,50 do 0,75 ili od –0,50 do –0,75 upućuju na umjerenu do dobru povezanost, te vrijednosti od 0,75 do 1,00 ili od –0,75 do –1,00 upućuju na vrlo dobru do izvrsnu po vezanost među varijablama [130].

Jedna od pretpostavki za uporabu regresijske analize jeste postojanje linearne ovisnosti između varijabli. Ona je neophodna jer analiza započinje izračunavanjem koeficijenata proste korelacije (bivarijantnih korelacija) za sve parove varijabli. Multikolinearnost pokazuje kolika je međuzavisnost između neovisnih varijabli. Multikolinearnost ili gotovo linearna ovisnost statistički je fenomen u kojem su dvije ili više prediktorskih varijabli u modelu višestruke regresije u visokoj korelaciji [131]. Međutim,

multikolinearnost nema utjecaja na procjenu i testiranje interakcije najvišeg reda. Višestruko regresijski (*multiple regresion, MR*) modeli ne pate od problema multikolinearnosti kada su neovisne varijable u visokoj korelaciji s ovisnom varijablom [132].

Prilikom izrade početne matrice korelacije svih varijabli potrebno je provjeriti postoji li multikolinearnost između neovisnih varijabli. Stupanj multikolinearnosti između 2 neovisne regresijske varijable može se odrediti upotrebom parne korelacije između dvije regresijske varijable [133].

S obzirom na to što je gore navedeno u ovom istraživanju izvršena je početna korelacijska analiza ulaznog seta podataka sa svim neovisnim i ovisnim varijablama. Izračunate su vrijednosti bivarijatnog odnosa između neovisnih i ovisnih varijabli kao mjere povezanosti varijabli i statistička značajnost izražena preko p-vrijednosti (pri $p<0,05$). Rezultati korelacijske analize su prikazani u vidu početne matrice korelacije u Prilogu 2. Zatim je izvršeno eliminiranje neovisnih i ovisnih varijabli koje imaju manju vrijednost koeficijenta korelacije i varijabli koje nisu statistički značajne. Početna korelacijska tablica pokazala je slijedeće:

- Varijabla X2 (srednja temperatura u sezoni grijanja) ima manji stupanj korelacije sa zavisnim varijablama u odnosu na varijablu X1 pa se ista isključuje iz daljnjih analiza.
- Varijabla X4 (broj korisnika po A_k) ima manji stupanj korelacije sa zavisnim varijablama u odnosu na varijablu X3, nije statistički značajna pa se ista isključuje iz daljnjih analiza.
- Varijabla X6 (postojanje školske dvorane) ima manji stupanj korelacije sa zavisnim varijablama, pa se ista isključuje iz daljnjih analiza.
- Varijable X7, X8 i X9 imaju veći stupanj korelacije sa zavisnim varijablama, međusobno su visoko korelirane, ostavit će se daljnje analize, ali se međusobno ne će uključivati u model.
- Varijable X12, X13, X14 i X15 imaju veći stupanj korelacije sa zavisnim varijablama, međusobno su visoko korelirane, ostavit će se daljnje analize, ali se međusobno ne će uključivati u model.
- Varijable X16, X17 i X18 imaju mali stupanj korelacije sa zavisnim varijablama pa se iste isključuju iz daljnjih analiza.

Iz Priloga 2 može se vidjeti kako postoji više neovisnih varijabli koje su statistički jako ili visoko značajne pa se može zaključiti da postoji barem jedna neovisna varijabla statistički značajno povezana s ovisnim varijablama (Y2 - ukupni godišnji troškovi isporučene toplinske energije $C_{QH,del}$, i Y2,cal - ukupni proračunski godišnji troškovi isporučene toplinske energije $C_{QH,del,cal}$).

Navedenim se može odbaciti postavljena nul-hipoteza H_0 kako se neovisnim varijablama ili karakteristikama školskih zgrada ne mogu procijeniti troškovi toplinske energije, odnosno prihvatiti alternativnu hipoteza H_1 kako se neovisnim varijablama ili karakteristikama školskih zgrada mogu procijeniti troškovi toplinske energije školskih zgrada u FBiH.

5.5 Metode za validaciju regresijskih modela

Zbog važnosti regresijske analize za odgovaranje na istraživačka pitanja vođena teorijom, svrha hijerarhijske regresijske analize utemeljene na teoriji je unošenje varijabli u regresijske jednadžbe unaprijed određenim redoslijedom koji je relevantan za teoriju i koja je temelj razvoja regresijskog modela. Ovaj postupak omogućuje određivanje inkrementalne predvidljivosti u svakom koraku regresije i varijance objašnjene varijablama koje se unose u svaki korak. Regresijske jednadžbe mogu se koristiti za odgovor na slijedeća teorijska istraživačka pitanja [129]:

- mogu li određene kombinacije neovisnih varijabli predvidjeti ili objasniti varijancu u zavisnoj varijabli?
- je li specifična varijabla u skupu neovisnih varijabli nužna za predviđanje ili objašnjenje varijance u zavisnoj varijabli? i
- mogu li određene kombinacije neovisnih varijabli predvidjeti ili objasniti varijancu u zavisnoj varijabli, s obzirom na snažno teorijsko obrazloženje za uključivanje kontrolnih varijabli kao prediktora?

Predviđanje je predikcija ili procjena stvarne vrijednosti u budućem vremenskom razdoblju ili za drugu situaciju (za zadane podatke). Model predviđanja (*forecasting model*) formalna je izjava o varijablama i odnosima među varijablama u stvaranju prognoza. Postoji mišljenje da se modeli s visokim R^2 (koeficijent determinacije) smatraju valjanim i točnim u svrhu predviđanja [134].

Najrasprostranjeniji statistički modeli za procjenu energetskih karakteristika zgrada su regresijski modeli koji povezuju potrošnju energije s jednom ili više varijabli. Uobičajena regresija najmanjih kvadrata pruža tehnički rigorozan pristup i daje opisne linearne jednadžbe koje su statistički valjane i lako ponovljive [31]. Standardni oblik jednadžbe višestruke linearne regresije s k neovisnih varijabli može se napisati u sljedećem obliku [89]:

$$\hat{Y} = a + b_1 \cdot X_1 + b_2 \cdot X_2 + ... + b_k \cdot X_k \tag{5.8}$$

gdje su:

- $\hat{Y}$ očekivana ili predviđena (regresijska) vrijednost ovisne varijable,

- a konstantni član (*intercept*) koji predstavlja očekivanu vrijednost ovisne varijable kada su vrijednosti neovisnih varijabli jednake nuli,
- $b_{1...k}$ regresijski koeficijenti (*coefficients*) koji pokazuju prosječnu promjenu neovisne varijable kada se odgovarajuća neovisna varijabla poveća za jednu jedinicu mjerenja a ostale neovisne varijable ostanu nepromijenjene i
- $X_{1...n}$ vrijednosti neovisnih varijabli.

Parametri regresijske jednadžbe određuju se metodom najmanjih kvadrata koja predstavlja minimum zbroja kvadrata rezidualnih odstupanja, odnosno minimum zbroja kvadrata odstupanja stvarnih vrijednosti ovisne varijable y_i i očekivanih (predviđenih) $\hat{y}_i$ vrijednosti [89].

Postavlja se pitanje u kojoj mjeri vrijednosti ovisne varijable očekivanih (predviđenih) rezultata modela odstupaju od stvarnih vrijednosti, odnosno koliko točno se mogu predvidjeti vrijednost ovisne varijable. Procjena reprezentativnosti modela bazira se na odstupanju stvarnih (y_i) od očekivanih ili regresijskih ($\hat{y}_i$) vrijednosti. Odstupanje stvarnih (y_i) vrijednosti od aritmetičke sredine $\overline{Y}$ može se podijeliti na regresijom protumačeno odstupanje ($\hat{y}_i - \overline{Y}$) i rezidualno (neprotumačeno) odstupanje ($y_i - \hat{y}_i$) što je prikazano na slici 5.2 [89].

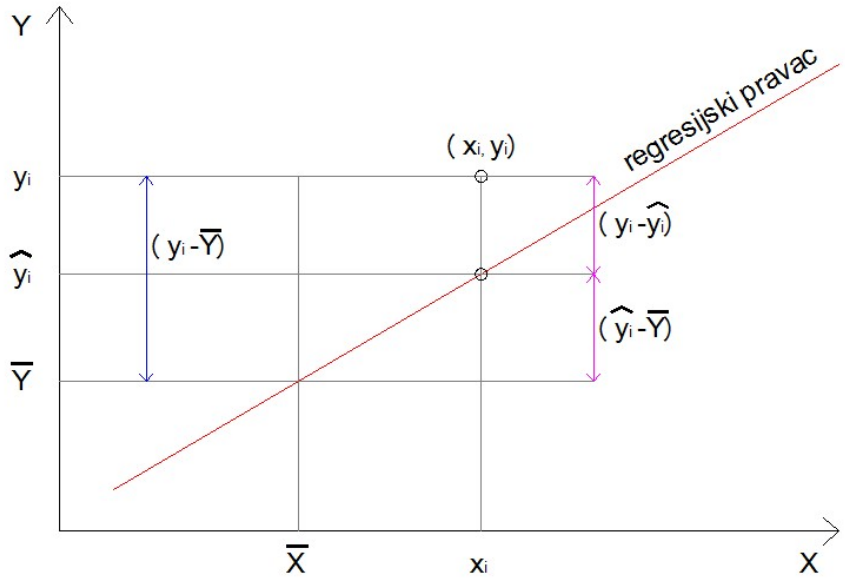

Slika 5.2 Prikaz ukupnog, protumačenog i neprotumačenog odstupanja za jednu točku [89]

Jednadžba analize varijance predstavlja temelj analize reprezentativnosti regresijskog modela [89]:

$$\sum_{t=1}^{n}(y_i-\overline{Y})^2=\sum_{t=1}^{n}(\hat{y}_i-\overline{Y})^2+\sum_{t=1}^{n}(y_i-\hat{y}_i)^2 \tag{5.9}$$

gdje su:

- $SST=\sum_{t=1}^{n}(y_i-\overline{Y})^2$ suma kvadrata odstupanja stvarnih vrijednosti y_i od aritmetičke sredine $\overline{Y}$,
- $SSR=\sum_{t=1}^{n}(\hat{y}_i-\overline{Y})^2$ suma kvadrata odstupanja regresijskih (predviđenih) $\hat{y}_i$ vrijednosti od aritmetičke sredine $\overline{Y}$ (odstupanje protumačeno regresijskim modelom) i
- $SSE=\sum_{t=1}^{n}(y_i-\hat{y}_i)^2$ suma kvadrata odstupanja stvarnih vrijednosti y_i od regresijskih (predviđenih) $\hat{y}_i$ vrijednosti (odstupanje neprotumačeno regresijskim modelom).

Kvaliteta regresijskog modela procjenjuje se uspoređivanjem rezultata regresijskog modela sa stvarnim vrijednostima. Razvijene su statističke metode za procjenu pogreške predviđanja regresijskih modela kako bi se prosudila kvaliteta regresijskog modela i omogućila usporedba regresijskih modela s drugim regresijskim modelima koji imaju s različite parametre.

Postavlja se pitanje koja je prikladna mjera za procjenu točnosti modela predviđanja? Kvaliteta (točnost) modela može se procijeniti ispitivanjem ulaznih podataka (pretpostavki) za model ili usporedbom rezultata (predviđanja) iz modela. Pogreška prognoze predstavlja razliku između prognozirane vrijednosti i stvarne vrijednosti. Točnost modela predviđanja može se mjeriti kroz dva različita stajališta [134]:

- ex post – gdje su poznata opažanja i o ovisnim (ishod prognoze) i neovisnim (objašnjenim) varijablama. Ex post prognoze mogu se provjeriti prema postojećim stvarnim podatcima i procijeniti koliko dobro model radi prognoze na temelju uzročnih (nezavisnih) varijabli.
- ex ante – prognoza daje vrijednosti ovisne varijable izvan razdoblja procjene (buduće razdoblje) i ne koristi stvarne vrijednosti objašnjavajućih varijabli iz budućih razdoblja.

Valjanost se može proučavati u smislu hoće li jednadžba uklopljena u izvorni uzorak dobro funkcionirati na izdvojenom uzorku iz prikupljenih izvornih podataka. Upotreba koeficijenta determinacije (R^2) u

jednostavnom izračunu uglavnom se može se koristiti za većinu vrsta problema i testova provjere valjanosti. Međutim, mogu se koristiti neke i druge tehnike za validaciju modela [135].

Razlika između stvarne vrijednosti y_i i regresijske vrijednosti modela $\hat{y}_i$ naziva se rezidual ili ostatak. Svaki izračunati ostatak za svaku točku u skupu podataka koristi se za procjenu modela. Ako je suma ili zbir svih reziduala mala, to znači da model koji ih je proizveo dobro odrađuje posao, a ako je ta suma reziduala velika, to implicira da je model loš procjenitelj. Razvijene su statističke metode koje uzimaju sumu ostataka i sažimaju ih u jednu vrijednost koja predstavlja prediktivnu sposobnost modela. Mnogo je ovih sažetih statističkih metoda, svaka sa svojim prednostima i manama [136].

Za ocjenu reprezentativnosti, sposobnosti modela da objasni kretanje ovisne varijable uz pomoć odabranih neovisnih varijabli, koriste se apsolutni i relativni pokazatelji. Ovi pokazatelji temelje se na raspodjeli odstupanja vrijednosti ovisne varijable y_i u regresijskom modelu od njene aritmetičke sredine $\overline{Y}$ i njenih očekivanih vrijednosti $\hat{y}_i$ [137].

Koeficijent determinacije (R^2) je pokazatelj reprezentativnosti regresijskog modela, koji se temelji na analizi varijance i definira se kao omjer sume kvadrata odstupanja protumačenih regresijom i sume kvadrata ukupnih odstupanja i može se odrediti sljedeći način [89]:

$$R^2 = \frac{\sum_{t=1}^{n}(\hat{y}_i - \overline{Y})^2}{\sum_{t=1}^{n}(y_i - \overline{Y})^2} \text{ ili } R^2 = 1 - \frac{\sum_{t=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{t=1}^{n}(y_i - \overline{Y})^2} \tag{5.10}$$

gdje su:

- y_i stvarne vrijednosti ovisne varijable,
- $\hat{y}_i$ predviđene ili očekivane vrijednosti ovisne varijable i
- $\overline{Y}$ aritmetička sredina ovisne varijable.

Vrijednost koeficijenta determinacije (R^2) kreće se u intervalu $0 \leq R^2 \leq 1$. Regresijski model je reprezentativniji ako je ova vrijednost bliža 1. Teorijska granica reprezentativnosti modela je 0,90. U praksi je ponekad vrlo teško pronaći varijablu koja dobro objašnjava ovisnu pojavu pa se ta granica reprezentativnosti spušta i do 0,60 [137]. Vrijednost indeksa determinacije R^2 u intervalu od 0,70 do 0,90 prema Chaddock-ovoj skali veza može se okarakterizirati kao jaka.

Koeficijent determinacije (R^2) je mjera koja objašnjava koliko neovisne varijable imaju udjela u objašnjavanju varijacija ovisne varijable. Glavna je poteškoća s ovom mjerom u tome što ona također može donijeti negativne vrijednosti za neovisnu varijablu, čak i ako neovisna varijabla čini veliku količinu varijance u ovisnoj varijabli, posebno ako je početna korelacija ili beta regresijski koeficijent za neovisnu varijablu negativan. Ako neovisne varijable generiraju velike negativne vrijednosti, jer se njihovi doprinosi varijance učinku regresije oduzimaju, stoga ih se ne bi trebalo koristiti u takvim slučajevima [129].

Za ocjenu reprezentativnosti modela višestruke regresije, uz prilagođeni koeficijent determinacije (R^2) i vrijednost statističke značajnosti p-vrijednost za validaciju modela koriste i druge metode [113].

Jedna od metoda koja se koristi za odabir između različitih modela je (*Sum of Square Errors, SSE*) metoda koja predstavlja apsolutni pokazatelj kvalitete modela na temelju sume kvadrata pogreške predviđanja. Pri odabiru regresijskih modela ovom tehnikom bira se model s najmanjom vrijednosti sume kvadrata odstupanja. Određuje se prema sljedećem izrazu [135]:

$$SSE = \sum_{t=1}^{n} (y_i - \hat{y}_i)^2 \tag{5.11}$$

gdje su:

- y_i stvarne vrijednosti ovisne varijable i
- $\hat{y}_i$ očekivane (regresijske) vrijednosti ovisne varijable.

Srednja kvadratna pogreška (*Mean Square Error, MSE*) ili varijanca regresije je apsolutna mjera koja predstavlja prosječno kvadratno odstupanje odnosno prosječnu kvadratnu razliku između stvarnih i predviđenih (regresijskih) vrijednosti. Određuje se prema sljedećem izrazu [135]:

$$MSE = \frac{1}{n} \sum_{t=1}^{n} (y_i - \hat{y}_i)^2 \tag{5.12}$$

gdje su:

- y_i stvarne vrijednosti ovisne varijable i
- $\hat{y}_i$ očekivane (regresijske) vrijednosti ovisne varijable.

MSE daje veću težinu velikim pogreškama nego manjim, jer se pogreške kvadriraju (povećavaju) prije nego što se zbroje. Budući da se sposobnost metode predviđanja za otkrivanje velikih pogrešaka često smatra jednim od najvažnijih kriterija, MSE metoda popularna je već godinama [134].

Korijen srednjeg kvadrata pogreške (*Root Mean Square Error, RMSE*) ili standardna pogreška (devijacija) regresije predstavlja apsolutnu mjeru reprezentativnosti modela. To je kvadratni korijen prosjeka kvadrata razlike između stvarnih i predviđenih vrijednosti podataka. RMSE je osjetljiv na izvanredne vrijednosti i to je jedna od glavnih slabosti ove procjene. Za stvarne skupove podataka, izvanredne vrijednosti mogu se jednostavno odbaciti da bi se koristila ova procjena. Matematički se određuje na sljedeći način [118]:

$$RMSE = \sqrt{\frac{1}{n}\sum_{t=1}^{n}(y_i - \hat{y})^2} \tag{5.13}$$

gdje su:

- y_i stvarne vrijednosti ovisne varijable i
- $\hat{y}_i$ očekivane (regresijske) vrijednosti ovisne varijable.

Standardna pogreška regresije (*RMSE*) izražava se u originalnim jedinicama mjere ovisne varijable y_i pa je teško uspoređivati reprezentativnosti regresijskih modela s različitim mjernim jedinicama. Ovaj problem se rješava koeficijentom varijacije regresijskog modela (*Coefficient of Variation of the Root Mean Square Error, CVRMSE*) koji predstavlja relativnu mjeru reprezentativnosti modela i predstavlja udio standardne pogreške regresije u odnosu na aritmetičku sredinu ovisne varijable [138]:

$$CVRMSE = \frac{\sqrt{\frac{1}{n}\sum_{t=1}^{n}(y_i - \hat{y})^2}}{\overline{Y}} \cdot 100(\%) \tag{5.14}$$

gdje su:

- y_i stvarne vrijednosti ovisne varijable i
- $\hat{y}_i$ očekivane (regresijske) vrijednosti ovisne varijable i
- $\overline{Y}$ aritmetička sredina ovisne varijable.

Opće načelo je pronaći optimalnu vrijednost parametara tako da se umanji odstupanje između vrijednosti predviđanja modela i stvarnih podataka [139]. Najmanja vrijednost koeficijenta varijacije je 0%, a najveća nije definirana. Vrijednosti koeficijenta varijacije od 0 do 10% predstavljaju vrlo slab varijabilitet, a od 10 do 30% relativno slab varijabilitet [89]. Što je koeficijent varijacije regresijskog modela bliži nuli, to je model reprezentativniji. Često se uzima dogovorena granica reprezentativnosti od 30%, pa ako je koeficijent varijacije manji od 30%, kaže se da je model dobar. Kod višestruke linearne regresije javlja se p parametara, pa se kod izračuna varijance koristi vrijednost n-p [137].

Srednja apsolutna postotna pogreška (*Mean Absolute Percentage Error, MAPE*) je srednja vrijednost ili prosjek zbroja svih postotnih pogrešaka za određeni skup podataka uzetih bez obzira na znak kako bi se izbjegao problem međusobnog poništavanja pozitivnih i negativnih vrijednosti [134]:

$$MAPE = \frac{1}{n}\sum_{t=1}^{n}\left|\frac{(y_i - \hat{y}_i)}{y_i}\right| \cdot 100(\%) \tag{5.15}$$

gdje su:

- y_i stvarne vrijednosti ovisne varijable i
- $\hat{y}_i$ očekivane (regresijske) vrijednosti ovisne varijable.

Svaki rezidual proporcionalno doprinosi ukupnoj količini pogreške, što znači da će veće pogreške linearno pridonijeti ukupnoj pogrešci. Postavlja se generalno pitanje kod razvoja regresijskih modela je li potrebno u model uključiti iznimke (*outliers*) ili ekstremne vrijednosti ili ih ignorirati, odnosno isključiti? Odgovor na ovo pitanje nije jednoznačan, ovisi o raspoloživim podatcima i posljedicama prije svega pogrešaka. Izuzetci su važni za odabir statističkih metoda za ocjenu pogreške modela, ovisno o tome želi li im se dati veće ili manje značenje u ukupnoj pogrešci. MAPE je robusniji na učinke iznimnih (*outliers*) vrijednosti u odnosu na RMSE. Međutim, nedostatak je da je MAPE pristran prema predviđanjima koja su sustavno manja od stvarnih vrijednosti [136].

Za ocjenu točnosti ili preciznosti modela može se izračunati srednja postotna pogreška (*Mean Percentage Error, MPE*) koja predstavlja odnos razlike između stvarnih i regresijskih vrijednosti predviđenih u odnosu na stvarne vrijednosti prema sljedećem izrazu [136]:

$$MPE = \frac{1}{n}\sum_{i=1}^{n}\left(\frac{(y_i - \hat{y}_i)}{y_i}\right) \cdot 100(\%) \tag{5.16}$$

gdje su:

- y_i stvarne vrijednosti ovisne varijable i
- $\hat{y}_i$ očekivane (regresijske) vrijednosti ovisne varijable.

Za razliku od MAPE-a, MPE je koristan jer omogućuje uvid u to kako regresijski model procjenjuje, da li sustavno podcjenjuje (negativna pogreška) ili precjenjuje (pozitivna pogreška).

5.6 Razvoj regresijskih modela procjene troškova toplinske energije školskih zgrada u FBiH

Postoji mnogo različitih strategija za odabir varijabli za regresijski model. Ako među varijablama kandidata postoji vrlo malo korelacije i ako ne postoje neobični problemi, sljedeća četiri postupka ili metode trebale bi pronaći isti model [127]:

- *Forward (Step-Up)* metoda često koristi za pružanje početnog pregleda varijabli kandidata kada postoji velika skupina varijabli. Ovaj postupak odabira koristi se unaprijed za dobivanje najboljih deset do petnaest varijabli. Ovaj postupak je također dobar izbor kada je multikolinearnost problem. Način odabira prema naprijed jednostavno je definirati. Počinje se bez varijabli kandidata u modelu a zatim se odabire varijabla koja ima najveći indeks determinacije R^2. Na svakom idućem koraku odabire se varijabla kandidata koja najviše povećava R^2. Prestaje se dodavati varijable kad ni jedna od preostalih varijabli nije značajna.
- *Backward (Step-Down)* metoda je manje popularna jer započinje modelom u koji su uključene sve varijable. U svakom se koraku uklanja varijabla koja je najmanje značajna. Taj se postupak nastavlja sve dok se ne uklone beznačajne varijable.
- *Stepwise* (postupna) metoda je kombinacija tehnika odabira prema naprijed (Forward) i prema natrag (Backward). Postupna regresija modifikacija je odabira prema naprijed tako da se nakon svakog koraka u koji je dodana varijabla provjeravaju sve varijable u modelu kako bi se utvrdilo je li njihov značaj smanjen ispod navedene razine tolerancije. Ako se pronađe beznačajna varijabla, ona se uklanja iz modela.
- *Mean Squared Errors (MSE)* je metoda slična metodi postupnog (stepwise) odabira. Međutim, umjesto da se koriste vjerojatnosti za dodavanje i uklanjanje varijabli, koristi se minimalna promjena srednje kvadratne pogreške. U svakom koraku odabire se varijabla čija će promjena (u modelu ili izvan njega) najviše smanjiti srednju kvadratnu pogrešku, a njezin status će se obrnuti.

Postupna (stepwise) metoda popularan je alat za istraživanje podataka koji koristi statističku značajnost za odabir objašnjenih varijabli koje će se koristiti u modelu višestruke regresije. Postupna regresija odabire objašnjene varijable za višestruke regresijske modele na temelju njihove statističke značajnosti. Istraživanje radova objavljenih 2004. godini u tri vodeća ekološka i bihevioralna časopisa otkrilo je da se 57% radova koji su izvijestili o višestrukim rezultatima regresije koristilo postupnu regresiju [116].

Postupna (stepwise) regresija je, prema svojoj najčešćoj definiciji, skup iterativnog postupka pretraživanja i usporedbe modela koji identificiraju koje neovisne varijable, za koje se prije smatralo da su od neke važnosti, imaju najjaču povezanost s ovisnom varijablom. Korištenjem postupnog postupka kombiniranja postaje moguće da varijable za koje je u kasnijim fazama utvrđeno da nisu značajne budu izbačene iz analize [140].

Višestruka linearna regresija (*Multiple Linear Regressions, MLR*) je metoda statistike koja se koristi za analizu odnosa između varijable pojedinačnog odgovora (ovisna varijabla) s dvije ili više kontroliranih varijabli (neovisne varijable). Opći koraci su provjera pretpostavki, odabir prikladnih metoda MLR-a, interpretacija rezultata i razvijanje jednadžbe MLR-a [141].

Regresijski modeli nemaju propisan pristup koji će pomoći procjeniteljima odabrati model procjene koji najbolje odgovara ulaznim i izlaznim varijablama uz zadanu najbolju točnost procjene. Prilikom provedbe regresijskih metoda, mora se pretpostaviti odnos između varijabli, s donekle ograničenim brojem ulaznih varijabli. U postupku postupne regresije vrši se identifikacija p-vrijednosti za svaku varijablu, a ako varijabla ima p-vrijednost veću od 0,05 vrši se uklanjanje do identifikacije najboljeg modela s konzistentnom varijablom, p-vrijednošću jednakom ili manjom od 0,05 [113].

Regresijska analiza predstavlja metodu kojom se, koristeći povijesne podatke statističkom analizom ključnih varijabli, vrši izvođenje modela gdje se komponente ovog modela uključuju u korelaciju. Ova metoda modeliranja široko se koristi u predviđanju troškova. S obzirom na troškove energije, regresija je idealan alat. Uključuje linearne, nelinearne i višestruke varijacije. Da bi procijenio održivost modela, korisnik to mora imati pristup i razumijevanje pretpostavki koje mu pridonose. Izbor modela treba se temeljiti na sljedećim atributima [33]:

- karakteristike podataka koji će se koristiti u smislu kvantitativni, kvalitativni, veliki/mali broj,
- opće znanje o problemu koji treba modelirati,
- opće znanje o graničnim uvjetima modela,
- pogreške koje model može generirati,

- ulazni i izlazni ciljevi i moguće posljedice,
- razumijevanje točnosti, pouzdanosti, valjanosti i osjetljivosti modela koji će se odabrati i
- razumijevanje parametara koji definiraju problem koji se modelira.

Regresijska analiza omogućuje analitičaru utvrđivanje i korištenje odnosa između varijable od interesa, koja se naziva ovisna varijabla ili varijabla odgovora, i jedne ili više neovisnih varijabli poznatih i kao prediktorske varijable. Glavne karakteristike statističke relacije u teoriji regresije su [25]:

- ovisna varijabla Y nastoji sustavno varirati s neovisnom varijablom X i
- raspršenost opažanja nastaje dijelom zbog drugih čimbenika uz neovisnu varijablu X koji utječu na ovisnu varijablu Y, a dijelom zbog svojstvene varijabilnosti Y.

Postupak prema naprijed postupne regresijske metode počinje uključivanjem prve neovisne varijable koja pokazuje najveću bivarijantnu korelaciju s ovisnom varijablom. Zatim se odabire druga neovisna varijabla daje najveći porast R^2 nakon obračunavanja predviđanja prve varijable. Nakon dodavanja druge neovisne varijable, provodi se drugi test značajnosti kako bi se utvrdilo ostaje li prva neovisna varijabla statistički značajan prediktor, ako nije, izbacuje se iz jednadžbe. Taj se postupak ponavlja sve dok sve neovisne varijable nisu unesene u jednadžbu ili ulazak preostalih neovisnih varijabli u postupno rješenje ne dovede do statistički značajnog povećanja R^2 [129].

Na slici 5.3 prikazan je dijagram toka razvoja regresijskih modela procjene troškova toplinske energije školskih zgrada u FBiH. Prvo je izvršeno razdvajanje osnovnog seta podataka na set za razvoj modela (*training set*) i set koji služi za validaciju (*validation set*) regresijskih modela. Zatim je izvršena početna korelacijska analiza svih neovisnih i ovisnih varijabli čime su određene vrijednosti jednostavne korelacije (stupanj povezanosti) između neovisnih i ovisnih varijabli. Varijable koje imaju manju vrijednost koeficijenta korelacije i koje nisu statistički značajne uklonjene su iz idućih analiza.

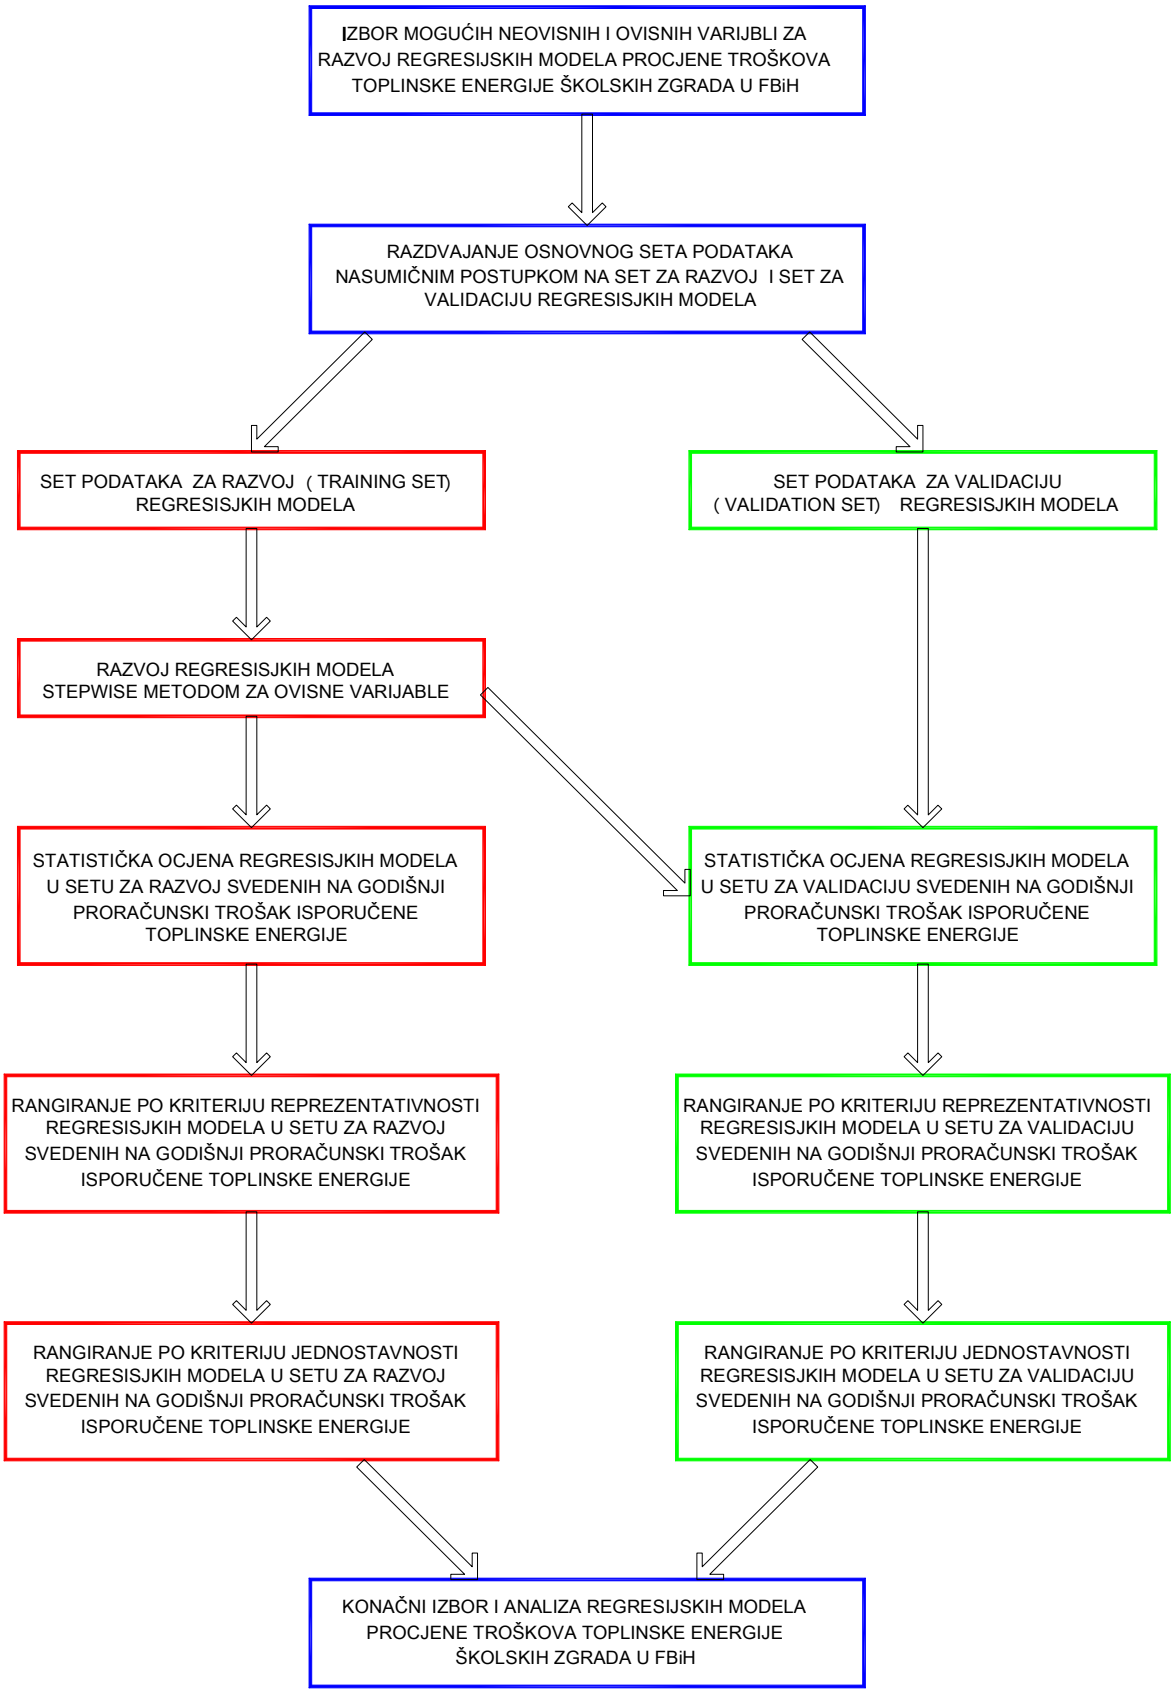

Slika 5.3 Dijagram toka razvoja regresijskih modela procjene troškova toplinske energije školskih zgrada u FBiH

U drugom koraku na setu za razvoj će se izvršiti razvoj regresijskih modela postupkom postupne (stepwise) regresijske metode naprijed te će se isti ocijenjeni statističkim metodama u setu za razvoj i setu za validaciju. Kako su ovisne varijable Y0,cal, Y0,cal,spec, Y1,cal i Y0,cal,spec bazirane na različitim jedinicama obračuna toplinske energije, i kako bi se rezultati statističke ocjene regresijskih modela mogli uspoređivati i u konačnici rangirati, izvršit će se proračuni ukupnih godišnjih proračunskih troškova isporučene toplinske energije ($C_{QH,del,cal}$) i za iste izvršiti statistička ocjena koristeći statističke metode i pokazatelje kao što su koeficijent determinacije (R^2), standardna pogreška regresije (RMSE), koeficijent varijacije (*CVRMSE*), srednja apsolutna postotna pogreška (*MAPE*) i srednja postotna pogreška (*MPE*).

Rangiranje regresijskih modela izvršit će se u odnosu na kriterij reprezentativnosti (najmanja pogreška regresije) i kriterij jednostavnosti modela (dostupne i lako mjerljive varijable) za oba seta podataka (set za razvoj i set za validaciju). Na kraju će se izvršiti odabir najboljih regresijskih modela koji u odnosu na dva postavljena kriterija (kriterij reprezentativnosti i kriterij jednostavnosti) i 2 seta podataka (set za razvoj i set za validaciju) daju najbolje rezultate, odnosno imaju najviše bodova.

U prvom poglavlju ovog rada definiran je se specifični cilj ovog istraživanja koji se odnosi na izradu matematičkih modela procjena troškova toplinske energije školskih zgrada u FBiH. U izradi (razvoju) regresijskih modela koristio se postupak postupne (*stepwise*) regresijske metode naprijed koristeći programski paket Statistica (verzija 8.0). Za skup podataka za razvoj (training set) regresijskih modela izvršena je regresijska analiza za sve ovisne varijable prikazane u tablici 5.2 te su sažeti rezultati prikazani u tablici 5.4.

Višestruki linearni regresijski modeli rangirani su za svaku ovisnu varijablu na temelju vrijednosti koeficijenta višestruke determinacije R^2 (razmatrani su modeli čiji su vrijednosti veće od 0,70). Usvojena je gornja vrijednost koeficijenta varijacije regresijskog modela (C*VRMSE*) od 30% [137] (modeli čija vrijednost *CVRMSE* prelazi vrijednost od 30% ne će se uključivati u daljnje razmatranje). Rangiranje u odnosu na pojedinačne ovisne varijable izvršeno je u odnosu na vrijednosti koeficijenta višestruke determinacije R^2. Konačan izbor modela izvršit će se nakon validacije.

Tablica 5.4 Regresijski modeli razvijeni na temelju seta za razvoj (training) za ovisne varijable

R. broj	Ovisna varijabla (Yi)	Neovisne varijable u modelu (Xi)	Oznaka modela	R^2	SSE	RMSE	CVRMSE
1	Y1	X1, X3, X10, X23, X27, X28	Y1-1	0,700	2,00E+12	119867,6	36,95%
2	Y0,cal	X1, X5, X7, X11, X15, X23	Y0,cal-1	0,921	6,19E+11	66751,6	17,33%
3	Y0,cal	X1, X5, X7, X15, X23	Y0,cal-2	0,918	6,44E+11	67814,8	17,61%
4	Y0,cal	X1, X5, X15, X23	Y0,cal-3	0,916	6,63E+11	68587,1	17,81%
5	Y0,cal	X1, X15, X23	Y0,cal-4	0,901	7,77E+11	73969,8	19,21%
6	Y0,cal	X1, X5, X7, X15, X19, X21	Y0,cal-5	0,884	9,10E+11	80923,6	21,01%
7	Y0,cal	X1, X5, X7, X15, X21	Y0,cal-6	0,878	9,57E+11	82677,9	21,47%
8	Y0,cal	X1, X23	Y0,cal-7	0,855	1,14E+12	89306,9	23,19%
9	Y0,cal	X1, X5, X7, X21	Y0,cal-8	0,850	1,18E+12	91321,2	23,72%
10	Y0,cal	X1, X3, X15, X21	Y0,cal-9	0,820	1,41E+12	100055,7	25,98%
11	Y0,cal	X1, X3, X21	Y0,cal-10	0,802	1,56E+12	104663,1	27,18%
12	Y0,cal	X1, X21	Y0,cal-11	0,794	1,62E+12	106294,4	27,60%
13	Y0,cal	X1, X5, X7	Y0,cal-12	0,762	1,87E+12	114702,1	29,79%
14	Y0,cal,spec	X1, X5, X10, X15, X24	Y0,cal,spec-1	0,826	1,36E+05	31,1	18,03%
15	Y0,cal,spec	X1, X5, X10, X24	Y0,cal,spec-2	0,814	1,44E+05	32,0	18,54%
16	Y0,cal,spec	X1, X5, X10, X19, X22	Y0,cal,spec-3	0,784	1,68E+05	34,6	20,05%
17	Y0,cal,spec	X1, X5, X10, X11, X19, X20	Y0,cal,spec-4	0,777	1,74E+05	35,3	20,47%
18	Y0,cal,spec	X1, X5, X10, X15, X22	Y0,cal,spec-5	0,773	1,76E+05	35,5	20,55%
19	Y0,cal,spec	X1, X10, X24	Y0,cal,spec-6	0,755	1,91E+05	36,6	21,22%
20	Y0,cal,spec	X1, X5, X10, X11, X20	Y0,cal,spec-7	0,745	1,98E+05	37,6	21,79%
21	Y0,cal,spec	X1, X5, X10, X19, X20	Y0,cal,spec-8	0,745	1,98E+05	37,6	21,80%
22	Y0,cal,spec	X1, X5, X10, X15, X20	Y0,cal,spec-9	0,730	2,10E+05	38,8	22,45%
23	Y0,cal,spec	X1, X5, X10, X20	Y0,cal,spec-10	0,715	2,22E+05	39,7	22,98%
24	Y1,cal	X1, X5, X15, X23, X26	Y1,cal-1	0,897	1,52E+12	104041,0	19,55%
25	Y1,cal	X1, X15, X23, X26	Y1,cal-2	0,889	1,63E+12	107607,1	20,22%
26	Y1,cal	X1, X15, X23	Y1,cal-3	0,852	2,17E+12	123706,0	23,25%
27	Y1,cal	X1, X3, X5, X15, X21, X26	Y1,cal-4	0,825	2,59E+12	135914,8	25,54%
28	Y1,cal	X1, X3, X15, X21, X26	Y1,cal-5	0,813	2,74E+12	139801,6	26,27%
29	Y1,cal	X1, X5, X12, X21, X26	Y1,cal-6	0,812	2,75E+12	140278,9	26,36%
30	Y1,cal	X1, X5, X15, X21, X26	Y1,cal-7	0,809	2,79E+12	141202,5	26,53%
31	Y1,cal	X1, X3, X15, X21	Y1,cal-8	0,792	3,04E+12	146898,1	27,60%
32	Y1,cal	X1, X5, X15, X21	Y1,cal-9	0,786	3,14E+12	149126,8	28,02%
33	Y1,cal	X1, X23	Y1,cal-10	0,772	3,35E+12	152945,5	28,74%
34	Y1,cal,spec	X1, X5, X10, X19, X24, X26	Y1,cal,spec-1	0,831	3,81E+05	52,4	21,30%
35	Y1,cal,spec	X1, X5, X10, X24, X26	Y1,cal,spec-2	0,821	4,04E+05	53,7	21,85%
36	Y1,cal,spec	X1, X10, X24, X26	Y1,cal,spec-3	0,790	4,73E+05	57,9	23,55%
37	Y1,cal,spec	X1, X5, X10, X22, X26	Y1,cal,spec-4	0,782	4,92E+05	59,3	24,10%
38	Y1,cal,spec	X1, X5, X10, X19, X20, X26	Y1,cal,spec-5	0,780	4,99E+05	59,7	24,28%
39	Y1,cal,spec	X1, X5, X10, X19, X26	Y1,cal,spec-6	0,757	5,49E+05	62,6	25,46%

40	Y1,cal,spec	X1, X5, X10, X20, X26	Y1,cal,spec-7	0,756	5,51E+05	62,7	25,51%
41	Y1,cal,spec	X1, X10, X22, X26	Y1,cal,spec-8	0,744	5,77E+05	64,0	26,00%
42	Y1,cal,spec	X1, X10, X20, X26	Y1,cal,spec-9	0,711	6,52E+05	68,0	27,66%
43	Y1,cal,spec	X1, X10, X19, X26	Y1,cal,spec-10	0,710	6,54E+05	68,1	27,69%
44	Y2,cal	X1, X15, X23, X26, X28	Y2,cal-1	0,812	5,18E+10	19231,6	35,2%
45	Y2,cal	X1, X23, X26, X28	Y2,cal-2	0,804	5,40E+10	19566,7	35,8%
46	Y2,cal	X1, X15, X23, X28	Y2,cal-3	0,797	5,55E+10	19912,3	36,5%
47	Y2,cal	X1, X23, X28	Y2,cal-4	0,786	5,89E+10	20369,4	37,3%
48	Y2,cal,spec	X1, X10, X20, X24, X28	Y2,cal,spec-1	0,796	6,09E+03	6,6	27,5%
49	Y2,cal,spec	X1, X5, X10, X20, X28	Y2,cal,spec-2	0,792	6,21E+03	6,7	27,7%
50	Y2,cal,spec	X1, X5, X20, X26, X28	Y2,cal,spec-3	0,775	6,71E+03	6,9	28,8%
51	Y2,cal,spec	X1, X10, X20, X28	Y2,cal,spec-4	0,765	7,01E+03	7,1	29,4%
52	Y2,cal,spec	X1, X5, X20, X28	Y2,cal,spec-5	0,741	7,74E+03	7,4	30,9%
53	Y2,cal,spec	X1, X5, X10, X28	Y2,cal,spec-6	0,736	7,88E+03	7,5	31,1%
54	Y2,cal,spec	X1, X20, X28	Y2,cal,spec-7	0,712	8,61E+03	7,8	32,4%

Korigirani ili prilagođeni koeficijent multiple determinacije (adj.R^2) primjenjuje se kod malog uzorka (N<30) pa se u tablici 5.4 nije prikazivao iako je izračunat. Statistička značajnost regresijskog modela određena je preko F omjera (*Significance F*) i prikazana preko p-vrijednosti. U tablici 5.4 prikazani su samo statistički značajni (pri p<0,05) regresijski modeli kao i regresijski koeficijenti. Regresijski modeli koji su statistički značajni, a imaju pojedine regresijske koeficijente koji nisu statistički značajni nisu prikazivani niti razmatrani.

Prilikom razvoja regresijskih modela za sve ovisne varijable prikazane u tablici 5.2 postupkom postupne (stepwise) regresijske metode utvrđeno je slijedeće:

- Ovisna varijabla Y1 ($Q_{H,del}$ godišnja stvarna isporučena toplinska energija za grijanje) samo u kombinaciji neovisnih varijabli X1, X3, X10, X23, X27 i X28 daje graničnu vrijednost koeficijenta determinacije R^2 od 0,70, ali koeficijent varijacije CVRMSE iznosi približno 37% (što je više od granične vrijednosti od 30%) pa se isti model ne će dalje razmatrati. Ni jedna druga kombinacija neovisnih varijabli ne daje vrijednost koeficijenta determinacije R^2 veću od 0,70 što ukazuje na neispunjavanje početnog uvjeta većeg stupnja korelacije neovisnih s ovisnom varijablom Y1. Navedeno potvrđuje energetski jaz između stvarne i potrebne (proračunske) isporučene toplinske energije što je analizirano poglavlju 4.3.

- Ovisna varijabla Y2 (godišnji trošak isporučene toplinske energije $C_{QH,del}$) prilikom razvoja regresijskih modela imala je vrijednosti koeficijenta determinacije R^2 manje od 0,70 pa se ista ovisna varijabla ne će dalje razmatrati. Kao i za prethodnu varijablu Y1 uzroci leže u

nedovoljnom stupnju korelacije neovisnih s ovisnom varijablom jer se energija, a time i troškovi istih, ne troše prema potrebama, nego prema mogućnostima.

- Ovisna varijabla Y2,cal (godišnji proračunski trošak isporučene toplinske energije $C_{QH,del,cal}$) u svim kombinacijama neovisnih varijabli ima vrijednosti koeficijenta varijacije CVRMSE veću od granične vrijednosti od 30% pa se isti modeli ne će dalje razmatrati.
- Ovisna varijabla Y2,cal,spec (godišnji specifični proračunski godišnji trošak isporučene toplinske energije $C'_{QH,del,cal}$) u nekim kombinacijama neovisnih varijabli ima vrijednosti koeficijenta varijacije CVRMSE veću od granične vrijednosti od 30% pa se isti modeli ne će dalje razmatrati.

Na temelju razvoja regresijskih modela za ovisne varijable Y1 i Y2 (koji predstavljaju stvarne vrijednosti potrošnje i troškova toplinske energije) nedovoljno korelirani s neovisnim varijablama pa isti nisu pogodni za razvoj regresijskih modela. Stoga će razvoj regresijskih modela za predviđanje troškova toplinske energije školskih zgrada u FBiH biti temeljen na proračunskim vrijednostima potrošnje i troškova toplinske energije (vrijednosti potrošnje i troškova toplinske energije koju bi školske zgrade u FBiH trebale imati da se griju onoliko koliko trebaju). Na temelju razvijenih regresijskih modela za procjenu troškova toplinske energije školskih zgrada u FBiH vlasnici školskih zgrada moći će izračunati koliko im toplinske energije treba i za koje iznose trebaju planirati budžet za troškove toplinske energije.

Kako proračunske ovisne varijable Y0,cal (godišnja proračunska potrebna toplinska energija za grijanje $Q_{H,nd,cal}$), Y0,cal,spec (godišnja proračunska specifična potrebna toplinska energija za grijanje $Q'_{H,nd,cal}$), Y1,cal (godišnja proračunska isporučena toplinska energija za grijanje $Q_{H,del,cal}$) i Y1,cal,spec (godišnja proračunska specifična isporučena toplinska energija za grijanje $Q'_{H,del,cal}$) predstavljaju potrošnju toplinske energije, a ne troškove toplinske energije, u idućem koraku će se, za set za razvoj i set za validaciju, izvršiti proračun godišnjih proračunskih troškova isporučene toplinske energije ($C_{QH,del,cal}$) što će predstavljati bazu za konačno rangiranje regresijskih modela.

Ulazni podatci pri razvoju regresijskih modela za ovisne varijable Y2, Y2,cal i Y2,cal,spec iskazani su u "konvertibilnim markama" (KM), ali će se jednadžbe bazirane na razvijenim regresijskim modelima za ukupne troškove toplinske energije iskazivati u eurima (EUR) množeći iste s faktorom 1,00 EUR/1,95583 KM.

Ukupni proračunski godišnji troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) određuju se preko višestruke linearne regresijske jednadžbe (u izrazima u nastavku koristit će se kratica VLRJ) za neovisnu varijablu Y0,cal (koja predstavlja proračunsku godišnju potrebnu toplinsku energiju za grijanje $Q_{H,nd,cal}$) prema sljedećem izrazu:

$$C_{QH,del,cal} = VLRJ\_Y0,cal \cdot (\frac{1}{\eta_{sys}} \cdot UC_{QH,del}) \cdot \frac{1}{1,95583} [EUR/god] \tag{5.17}$$

gdje su:

- $VLRJ\_Y0,cal$ višestruka linearna regresijska jednadžba za godišnju proračunsku potrebnu toplinsku energiju za grijanje $Q_{H,nd,cal}$ (kWh/god),
- η_{sys} učinkovitost sustava grijanja i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Ukupni godišnji proračunski troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) određuju se preko višestruke linearne regresijske jednadžbe (VLRJ) za neovisnu varijablu Y0,cal,spec (koja predstavlja godišnju proračunsku specifičnu potrebnu toplinsku energiju za grijanje $Q'_{H,nd,cal}$) prema sljedećem izrazu:

$$C_{QH,del,cal} = VLRJ\_Y0,cal,spec \cdot (\frac{1}{\eta_{sys}} \cdot A_K \cdot UC_{QH,del}) \cdot \frac{1}{1,95583} [EUR/god] \tag{5.18}$$

gdje su:

- $VLRJ\_Y0,cal,spec$ višestruka linearna regresijska jednadžba za godišnju proračunsku specifičnu potrebnu toplinsku energiju za grijanje $Q'_{H,nd,cal}$ (kWh/m^{2}god),
- A_K korisna površina zgrade,
- η_{sys} učinkovitost sustava grijanja i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Ukupni godišnji proračunski troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) određuju se preko višestruke linearne regresijske jednadžbe (VLRJ) za neovisnu varijablu Y1,cal (koja predstavlja godišnju proračunsku isporučenu toplinsku energiju za grijanje $Q_{H,del,cal}$) prema sljedećem izrazu:

$$C_{QH,del,cal} = VLRJ\_Y1,cal \cdot UC_{QH,del} \cdot \frac{1}{1,95583} [EUR/god] \tag{5.19}$$

gdje su:

- $VLRJ\_Y1,cal$ višestruka linearna regresijska jednadžba za godišnju proračunsku specifičnu isporučenu toplinsku energiju za grijanje $Q_{H,del,cal}$ (kWh/god) i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Ukupni godišnji proračunski troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) određuju se preko višestruke linearne regresijske jednadžbe (VLRJ) za neovisnu varijablu Y1,cal,spec (koja predstavlja godišnju proračunsku specifičnu isporučenu toplinsku energiju za grijanje $Q'_{H,del,cal}$) prema sljedećem izrazu:

$$C_{QH,del,cal} = VLRJ\_Y1,cal,spec \cdot A_K \cdot UC_{QH,del} \cdot \frac{1}{1,95583} [EUR/god] \tag{5.20}$$

gdje su:

- $VLRJ\_Y1,cal,spec$ višestruka linearna regresijska jednadžba za godišnju proračunsku specifičnu isporučenu toplinsku energiju za grijanje $Q'_{H,del,cal}$ (kWh/m^{2}god),
- A_K korisna površina zgrade i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Ukupni godišnji proračunski troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) određuju se preko višestruke linearne regresijske jednadžbe (VLRJ) za neovisnu varijablu Y2,cal,spec (koja predstavlja godišnji proračunski specifični trošak isporučene toplinske energiju za grijanje $C''_{QH,del,cal}$) prema sljedećem izrazu:

$$C_{QH,del,cal} = VLRJ\_Y2,cal,spec \cdot A_K \cdot \frac{1}{1,95583} \left[EUR/god \right] \tag{5.21}$$

gdje su:

- $VLRJ\_Y2,cal,spec$ višestruka linearna regresijska jednadžba za godišnji specifični proračunski trošak isporučene toplinske energije $C'_{QH,del,cal}$ (EUR/m^{2}god) i
- A_K korisna površina zgrade.

5.7 Validacija regresijskih modela procjene troškova toplinske energije školskih zgrada u FBiH na setu za razvoj i validaciju

Svaka metoda predviđanja temelji se na pretpostavkama o ponašanju uključenih varijabli i preciznosti s kojom su usvojene matematičke relacije. Da bi se pristup modeliranja mogao primijeniti s razumnim stupnjem pouzdanosti, mora se potvrditi, odnosno mora se izvršiti provjera valjanosti ili validacija razvijenih regresijskih modela [31].

Validacija je umjetnost, a ne znanost, jer uklanjanje nestabilnih varijabli, kao i različite vrste razdvajanja podataka, uporaba novih podataka i prilagodbe za vanjske razlike kada se test uzorci koriste iz različitih vremenskih razdoblja mogu dovesti do različitih odluka o tome hoće li jednadžbe biti potvrđene. Za pronalaženje učinkovite valjanosti mogu se koristiti razne strategije s obzirom na izbor metoda ispitivanja, izbor podataka za provjeru valjanosti, reviziju regresijskih jednadžbi i prilagodbu podataka za provjeru valjanosti [135].

Kako su regresijski modeli prikazani u tablici 5.4 za ovisne varijable Y0,cal, Y0,cal,spec, Y1,cal i Y0,cal,spec razvijeni u odnosu na različite jedinice obračuna toplinske energije, i kako bi se isti mogli uspoređivati i u konačnici rangirati, izvršeni su proračuni ukupnih godišnjih proračunskih troškova za isporučenu toplinsku energiju ($C_{QH,del,cal}$) u funkciji razvijenih regresijskih modela koristeći izraze od 5.17 do 5.21.

Stoga je za sve razvijene regresijske modele iz tablice 5.4 (osim za modele čija je vrijednost *CVRMSE* veća od 30%) izvršen proračun godišnjih proračunskih troškova isporučene toplinske energije ($C_{QH,del,cal}$) koristeći setove podataka za razvoj i set podataka za validaciju kako bi se mogla izvršiti usporedba rezultata svih modela u istim uvjetima, te za različite setove podataka.

Za ocjenu pogreške regresijskih modela izračunate su vrijednosti koeficijenata determinacije (R^2), standardne pogreške regresije (*RMSE*), koeficijenata varijacije (*CVRMSE*), srednje apsolutne postotne pogreške (*MAPE*) i srednje postotna pogreška (*MPE*). U tablici 5.5 prikazane su vrijednosti statističkih metoda za ocjenu pogreške regresijskih modela u odnosu na set za razvoj (*training set*) modela i u odnosu na set za validaciju (*validation set*). Cilj je preliminarno procijeniti regresijske modele prema navedenim statističkih metoda kako bi se u idućoj fazi izvršilo rangiranje istih.

Tablica 5.5 Vrijednosti statističkih metoda ocjene regresijskih modela svedenih na ovisnu varijablu Y2,cal (godišnji proračunski trošak isporučene toplinske energije $C_{QH,del,cal}$)

		Set za razvoj (training set)					Set za validaciju (validation set)				
Red. Broj	Oznaka modela	R^2	RMSE	CVRMSE	MAPE	MPE	R^2	RMSE	CVRMSE	MAPE	MPE
1	Y0,cal-1	0,918	6524,1	23,37%	31,51%	12,23%	0,928	7967,4	25,76%	17,27%	-9,44%
2	Y0,cal-2	0,913	6681,0	23,94%	34,41%	15,37%	0,934	7518,4	24,31%	15,40%	-8,81%
3	Y0,cal-3	0,913	6676,9	23,92%	35,45%	15,63%	0,936	7310,3	23,64%	15,27%	-8,27%
4	Y0,cal-4	0,905	6942,2	24,87%	35,58%	13,86%	0,920	8054,5	26,04%	21,05%	-5,64%
5	Y0,cal-5	0,879	7909,6	28,34%	36,20%	14,29%	0,881	10255,4	33,16%	18,23%	-8,16%
6	Y0,cal-6	0,877	7942,0	28,45%	37,51%	14,15%	0,901	9213,2	29,79%	19,13%	-8,65%
7	Y0,cal-7	0,875	7921,0	28,38%	40,27%	13,24%	0,875	9912,4	32,05%	23,68%	-8,40%
8	Y0,cal-8	0,858	8517,8	30,52%	41,45%	14,41%	0,874	10248,3	33,13%	19,94%	-11,36%
9	Y0,cal-9	0,838	9099,9	32,60%	41,90%	11,96%	0,905	8877,1	28,70%	22,72%	-5,07%
10	Y0,cal-10	0,818	9586,5	34,35%	43,42%	11,76%	0,887	9546,6	30,87%	23,29%	-6,69%
11	Y0,cal-11	0,814	9665,1	34,63%	43,04%	11,04%	0,871	10036,1	32,45%	23,83%	-5,60%
12	Y0,cal-12	0,819	9561,0	34,25%	37,92%	3,75%	0,703	15465,4	50,00%	32,86%	-19,24%
13	Y0,cal,spec-1	0,931	5956,0	21,34%	16,65%	-0,04%	0,861	10925,4	35,32%	18,50%	4,35%
14	Y0,cal,spec-2	0,940	5512,6	19,75%	16,40%	-0,22%	0,897	9265,8	29,96%	16,56%	3,34%
15	Y0,cal,spec-3	0,923	6293,8	22,55%	17,51%	-1,41%	0,883	10023,4	32,41%	16,48%	4,05%
16	Y0,cal,spec-4	0,920	6437,5	23,06%	18,79%	-3,45%	0,841	11863,2	38,36%	14,66%	3,51%
17	Y0,cal,spec-5	0,910	6791,7	24,33%	18,48%	-1,91%	0,821	12371,6	40,00%	19,32%	6,55%
18	Y0,cal,spec-6	0,923	6243,8	22,37%	18,12%	-1,50%	0,866	10554,8	34,13%	18,05%	2,66%
19	Y0,cal,spec-7	0,920	6421,4	23,01%	19,71%	-3,02%	0,910	8793,0	28,43%	13,28%	5,70%
20	Y0,cal,spec-8	0,912	6732,9	24,12%	19,34%	-2,67%	0,771	13994,1	45,25%	17,01%	3,60%
21	Y0,cal,spec-9	0,907	6912,0	24,76%	19,56%	-4,56%	0,806	12893,9	41,69%	17,40%	4,13%
22	Y0,cal,spec-10	0,913	6653,5	23,84%	19,75%	-2,29%	0,830	11870,4	38,38%	15,36%	5,99%
23	Y1,cal-1	0,897	7269,3	26,04%	36,36%	14,59%	0,920	8257,7	26,70%	20,06%	-3,54%
24	Y1,cal-2	0,893	7387,0	26,47%	35,41%	12,85%	0,891	9517,7	30,77%	24,95%	-1,04%
25	Y1,cal-3	0,872	8026,9	28,76%	33,22%	7,49%	0,868	10321,3	33,37%	25,05%	-10,49%
26	Y1,cal-4	0,840	9099,5	32,60%	42,13%	12,93%	0,916	8605,5	27,82%	21,03%	-5,71%
27	Y1,cal-5	0,831	9311,9	33,36%	41,29%	10,87%	0,888	9796,9	31,68%	26,93%	-2,54%
28	Y1,cal-6	0,826	9456,6	33,88%	42,81%	12,90%	0,861	10907,3	35,27%	21,95%	-5,43%

29	Y1,cal-7	0,828	9385,0	33,62%	41,75%	11,68%	0,896	9451,8	30,56%	22,38%	-4,35%
30	Y1,cal-8	0,824	9479,1	33,96%	38,61%	7,45%	0,859	10820,1	34,98%	28,12%	-9,23%
31	Y1,cal-9	0,821	9541,3	34,18%	39,12%	7,73%	0,862	10726,6	34,68%	27,32%	-10,91%
32	Y1,cal-10	0,842	8912,4	31,93%	39,57%	5,85%	0,829	11578,3	37,43%	31,78%	-14,48%
33	Y1,cal,spec-1	0,885	7725,6	27,68%	20,12%	1,78%	0,818	12694,8	41,04%	22,89%	8,20%
34	Y1,cal,spec-2	0,916	6559,7	23,50%	20,15%	0,77%	0,879	10192,5	32,95%	19,96%	6,02%
35	Y1,cal,spec-3	0,909	6826,7	24,46%	21,18%	-1,19%	0,848	11223,7	36,29%	20,61%	4,67%
36	Y1,cal,spec-4	0,887	7614,6	27,28%	22,25%	-1,28%	0,841	11668,2	37,73%	20,53%	8,19%
37	Y1,cal,spec-5	0,911	6790,3	24,33%	21,93%	-1,75%	0,719	15775,3	51,00%	19,55%	6,75%
38	Y1,cal,spec-6	0,886	7646,0	27,39%	23,49%	-2,89%	0,670	16805,7	54,34%	21,02%	3,89%
39	Y1,cal,spec-7	0,882	7768,0	27,83%	23,02%	-2,52%	0,797	13196,7	42,67%	18,66%	7,95%
40	Y1,cal,spec-8	0,871	8117,9	29,08%	23,34%	-3,13%	0,804	12774,1	41,30%	21,18%	7,68%
41	Y1,cal,spec-9	0,863	8372,2	30,00%	23,93%	-4,22%	0,742	14630,7	47,30%	19,85%	7,96%
42	Y1,cal,spec-10	0,838	9075,6	32,52%	25,11%	-6,51%	0,570	18909,3	61,14%	26,69%	1,12%
43	Y2,cal,spec-1	0,868	8239,0	29,52%	25,62%	0,35%	0,816	12742,6	41,20%	29,94%	-11,99%
44	Y2,cal,spec-2	0,862	8430,8	30,21%	25,67%	-4,62%	0,800	13097,2	42,35%	23,71%	-9,91%
45	Y2,cal,spec-3	0,800	10138,6	36,32%	31,87%	-17,45%	0,807	12862,0	41,59%	34,93%	-27,85%
46	Y2,cal,spec-4	0,844	8911,7	31,93%	28,39%	-5,94%	0,767	13914,3	44,99%	26,54%	-11,35%

U tablici 5.5 crvenim poljima označeni modeli čije vrijednosti CVRMSE i MAPE prelaze graničnu vrijednost od 30%. Modeli koji veći imaju srednju apsolutnu postotnu pogrešku (*MAPE*) ukazuju na postojanje većeg sustavnog odstupanja ili pogreške u modelu, i takve modele je vrlo teško popraviti. Regresijski modeli koji imaju istovremeno veće vrijednosti CVRMSE i MAPE općenito su loši modeli i takve modele je teško popraviti, te se uglavnom odbacuju.

Analizom vrijednosti statističkih metoda ocjene regresijskih modela koji se odnose na set za razvoj modela može se uočiti slijedeće:

- Regresijski modeli za ovisne varijable Y0,cal i Y1,cal imaju vrijednosti za MAPE veće od 30% i dijelom za koeficijent CVRMSE. Navedeno upućuje na sustavne probleme ovih regresijskih modela posebno u zajedničkoj kombinaciji većih vrijednosti MAPE i CVRMSE.
- Regresijski modeli za ovisnu varijablu Y2,cal,spec imaju veće vrijednosti za koeficijent CVRMSE što upućuje na postojanje ekstremnih vrijednosti (outliers).

Također, uočavaju se veće pozitivne vrijednosti srednje postotne pogreške (MPE) na regresijskim modelima za ovisne varijable Y0,cal i Y1,cal što upućuje na generiranje manjih regresijskih vrijednosti u odnosu na stvarne vrijednosti na setu podataka za razvoj modela.

Postavlja se pitanje koji model najbolje može opisati i predvidjeti vrijednosti na novim setovima podataka. S obzirom na veliki broj različitih modela, za izbor ''najboljih'' modela definiraju se sljedeći kriteriji:

- Reprezentativnost, odnosno točnost modela, tj. koliko je model sposoban dobro objasniti kretanje ovisne varijable uz pomoć odabranih neovisnih varijabli. Pri tome se koriste prethodno opisane statističke metode za ocjenu točnosti modela [137].
- Jednostavnost, koja se ogleda u prikupljanju manjeg broja neovisnih varijabli uz odgovarajuću točnost procjene ovisne varijable koje su jednostavno mjerljive. Manji model s manje kovarijacija može dati bolja predviđanja od velikog modela i jednostavniji je. Bitno je da u model budu uključene istinski važne varijable koje su relativno jednostavno mjerljive [128].

U odnosu na kriterij reprezentativnosti modela izvršeno je rangiranje svih modela prikazanih u tablici 5.6 koristeći apsolutni pokazatelj standardne pogreške regresije (*RMSE*) i relativni pokazatelj srednje apsolutne postotne pogreške (*MAPE*). Koeficijent varijacije (*CVRMSE*) ne će se koristiti jer nije ista srednja vrijednost ovisne varijable na temelju koje se izračunava CVRMSE za set za razvoj modela i set za validaciju pa se isti ne mogu uspoređivati.

Tablica 5.6 Rangiranje regresijskih modela svedenih na ovisnu varijablu Y2,cal preko statističkih metoda RMSE i MAPE

Red. Broj	Set za razvoj (*training set*)				Set za validaciju (*validation set*)				Broj bodova
	RMSE	Oznaka modela	MAPE	Oznaka modela	RMSE	Oznaka modela	MAPE	Oznaka modela	
1	5512,6	Y0,cal,spec-2	16,40%	Y0,cal,spec-2	7310,3	Y0,cal-3	13,28%	Y0,cal,spec-7	10
2	5956,0	Y0,cal,spec-1	16,65%	Y0,cal,spec-1	7518,4	Y0,cal-2	14,66%	Y0,cal,spec-4	9
3	6243,8	Y0,cal,spec-6	17,51%	Y0,cal,spec-3	7967,4	Y0,cal-1	15,27%	Y0,cal-3	8
4	6293,8	Y0,cal,spec-3	18,12%	Y0,cal,spec-6	8054,5	Y0,cal-4	15,36%	Y0,cal,spec-10	7
5	6421,4	Y0,cal,spec-7	18,48%	Y0,cal,spec-5	8257,7	Y1,cal-1	15,40%	Y0,cal-2	6
6	6437,5	Y0,cal,spec-4	18,79%	Y0,cal,spec-4	8605,5	Y1,cal-4	16,48%	Y0,cal,spec-3	5
7	6524,1	Y0,cal-1	19,34%	Y0,cal,spec-8	8793,0	Y0,cal,spec-7	16,56%	Y0,cal,spec-2	4
8	6559,7	Y1,cal,spec-2	19,56%	Y0,cal,spec-9	8877,1	Y0,cal-9	17,01%	Y0,cal,spec-8	3
9	6653,5	Y0,cal,spec-10	19,71%	Y0,cal,spec-7	9213,2	Y0,cal-6	17,27%	Y0,cal-1	2
10	6676,9	Y0,cal-3	19,75%	Y0,cal,spec-10	9265,8	Y0,cal,spec-2	17,40%	Y0,cal,spec-9	1
11	6681,0	Y0,cal-2	20,12%	Y1,cal,spec-1	9451,8	Y1,cal-7	18,05%	Y0,cal,spec-6	0
12	6732,9	Y0,cal,spec-8	20,15%	Y1,cal,spec-2	9517,7	Y1,cal-2	18,23%	Y0,cal-5	0
13	6790,3	Y1,cal,spec-5	21,18%	Y1,cal,spec-3	9546,6	Y0,cal-10	18,50%	Y0,cal,spec-1	0
14	6791,7	Y0,cal,spec-5	21,93%	Y1,cal,spec-5	9796,9	Y1,cal-5	18,66%	Y1,cal,spec-7	0
15	6826,7	Y1,cal,spec-3	22,25%	Y1,cal,spec-4	9912,4	Y0,cal-7	19,13%	Y0,cal-6	0

16	6912,0	Y0,cal,spec-9	23,02%	Y1,cal,spec-7	10023,4	Y0,cal,spec-3	19,32%	Y0,cal,spec-5	0
17	6942,2	Y0,cal-4	23,34%	Y1,cal,spec-8	10036,1	Y0,cal-11	19,55%	Y1,cal,spec-5	0
18	7269,3	Y1,cal-1	23,49%	Y1,cal,spec-6	10192,5	Y1,cal,spec-2	19,85%	Y1,cal,spec-9	0
19	7387,0	Y1,cal-2	23,93%	Y1,cal,spec-9	10248,3	Y0,cal-8	19,94%	Y0,cal-8	0
20	7614,6	Y1,cal,spec-4	25,11%	Y1,cal,spec-10	10255,4	Y0,cal-5	19,96%	Y1,cal,spec-2	0
21	7646,0	Y1,cal,spec-6	25,62%	Y2,cal,spec-1	10321,3	Y1,cal-3	20,06%	Y1,cal-1	0
22	7725,6	Y1,cal,spec-1	25,67%	Y2,cal,spec-2	10554,8	Y0,cal,spec-6	20,53%	Y1,cal,spec-4	0
23	7768,0	Y1,cal,spec-7	28,39%	Y2,cal,spec-4	10726,6	Y1,cal-9	20,61%	Y1,cal,spec-3	0
24	7909,6	Y0,cal-5	31,51%	Y0,cal-1	10820,1	Y1,cal-8	21,02%	Y1,cal,spec-6	0
25	7921,0	Y0,cal-7	31,87%	Y2,cal,spec-3	10907,3	Y1,cal-6	21,03%	Y1,cal-4	0
26	7942,0	Y0,cal-6	33,22%	Y1,cal-3	10925,4	Y0,cal,spec-1	21,05%	Y0,cal-4	0
27	8026,9	Y1,cal-3	34,41%	Y0,cal-2	11223,7	Y1,cal,spec-3	21,18%	Y1,cal,spec-8	0
28	8117,9	Y1,cal,spec-8	35,41%	Y1,cal-2	11578,3	Y1,cal-10	21,95%	Y1,cal-6	0
29	8239,0	Y2,cal,spec-1	35,45%	Y0,cal-3	11668,2	Y1,cal,spec-4	22,38%	Y1,cal-7	0
30	8372,2	Y1,cal,spec-9	35,58%	Y0,cal-4	11863,2	Y0,cal,spec-4	22,72%	Y0,cal-9	0
31	8430,8	Y2,cal,spec-2	36,20%	Y0,cal-5	11870,4	Y0,cal,spec-10	22,89%	Y1,cal,spec-1	0
32	8517,8	Y0,cal-8	36,36%	Y1,cal-1	12371,6	Y0,cal,spec-5	23,29%	Y0,cal-10	0
33	8911,7	Y2,cal,spec-4	37,51%	Y0,cal-6	12694,8	Y1,cal,spec-1	23,68%	Y0,cal-7	0
34	8912,4	Y1,cal-10	37,92%	Y0,cal-12	12742,6	Y2,cal,spec-1	23,71%	Y2,cal,spec-2	0
35	9075,6	Y1,cal,spec-10	38,61%	Y1,cal-8	12774,1	Y1,cal,spec-8	23,83%	Y0,cal-11	0
36	9099,5	Y1,cal-4	39,12%	Y1,cal-9	12862,0	Y2,cal,spec-3	24,95%	Y1,cal-2	0
37	9099,9	Y0,cal-9	39,57%	Y1,cal-10	12893,9	Y0,cal,spec-9	25,05%	Y1,cal-3	0
38	9311,9	Y1,cal-5	40,27%	Y0,cal-7	13097,2	Y2,cal,spec-2	26,54%	Y2,cal,spec-4	0
39	9385,0	Y1,cal-7	41,29%	Y1,cal-5	13196,7	Y1,cal,spec-7	26,69%	Y1,cal,spec-10	0
40	9456,6	Y1,cal-6	41,45%	Y0,cal-8	13914,3	Y2,cal,spec-4	26,93%	Y1,cal-5	0
41	9479,1	Y1,cal-8	41,75%	Y1,cal-7	13994,1	Y0,cal,spec-8	27,32%	Y1,cal-9	0
42	9541,3	Y1,cal-9	41,90%	Y0,cal-9	14630,7	Y1,cal,spec-9	28,12%	Y1,cal-8	0
43	9561,0	Y0,cal-12	42,13%	Y1,cal-4	15465,4	Y0,cal-12	29,94%	Y2,cal,spec-1	0
44	9586,5	Y0,cal-10	42,81%	Y1,cal-6	15775,3	Y1,cal,spec-5	31,78%	Y1,cal-10	0
45	9665,1	Y0,cal-11	43,04%	Y0,cal-11	16805,7	Y1,cal,spec-6	32,86%	Y0,cal-12	0
46	10138,6	Y2,cal,spec-3	43,42%	Y0,cal-10	18909,3	Y1,cal,spec-10	34,93%	Y2,cal,spec-3	0

Nakon izvršenog rangiranja svih modela prema kriterijima najnižih vrijednosti RMSE i MAPE prikazanih u tablici 5.6 izvršeno je bodovanje modela na način prikazan u krajnjoj desnoj koloni tablice (dodijeljeni su bodovi za 10 prvoplasiranih modela). Bodovi su dodijeljeni na način da je prvoplasiranom dodijeljeno 10 bodova, drugoplasiranom 9 bodova i redom do deseto plasiranog kome je dodijeljen 1 bod.

Analizirajući vrijednosti statističkih metoda ocjene regresijskih modela koji se odnose na set za razvoj modela može se uočiti slijedeće:

- Najbolje rezultate općenito imaju modeli bazirani na ovisnoj varijabli Y0,cal,spec koja predstavlja vrijednosti proračunske specifične potrebne toplinske energije svedenih na ovisnu varijablu Y2,cal.
- Model s oznakom Y0,cal,spec-2 (neovisne varijable X1, X5, X10, X24) je prvoplasirani u setu za razvoj modela, ali se također nalazi među prvih 10 rezultata u setu za validaciju modela.
- Model s oznakom Y0,cal,spec-7 (neovisne varijable X1, X5, X10, X11, X20) je drugoplasirani dok je model Y0,cal-3 (neovisne varijable X1, X5, X15, X23) najbolje rangirani u setu za validaciju modela, ali se u setu za razvoj modela po kriteriju MAPE ne nalazi među prvih 10.

Istraživanjem pojedinih vrijednosti u razvijenim regresijskim modelima mogu se uočiti dvije vrste podataka koji imaju nerealne vrijednosti ili čije vrijednosti su ekstremne. Prva vrsta podataka se odnosi na očekivane (regresijske) vrijednosti $\hat{y}_i$ ovisne varijable koji imaju negativni predznak i generiraju negativne vrijednosti godišnjeg proračunskog troška isporučene toplinske energije $C_{QH,del,cal}$ što nije realno. Ovaj problem je riješen na način da se negativne vrijednosti očekivane vrijednosti $\hat{y}_i$ ovisne varijable izjednače s nulom čime se vrijednosti ne isključuju iz modela i apsolutna postotna pogreška (*MAPE*) iznosi 100%. Najveći broj od 8 negativnih vrijednosti očekivane vrijednosti $\hat{y}_i$ ovisne varijable u setu za razvoj (*training set*) nalaze se u regresijskim modelima koji su bazirani na ovisnoj varijabli Y0,cal.

Druga vrsta podataka odnosi se na ekstremne vrijednosti (*outliers*) koji predstavljaju podatke koji se nalaze na abnormalnoj udaljenosti od drugih vrijednosti u slučajnom uzorku. U ovom istraživanju to se odnosi na ekstremne vrijednosti razlike stvarne vrijednosti y_i i očekivane vrijednosti $\hat{y}_i$ ovisne varijable godišnjeg proračunskog troška isporučene toplinske energije $C_{QH,del,cal}$. Navedene ekstremne vrijednosti utječu na proračun standardne pogreške regresije (*RMSE*) i negativno se odražavaju na mjeru reprezentativnosti regresijskog modela. RMSE je osjetljiv na izvanredne ili ekstremne vrijednosti (*outliers*) i to ova metoda ukazuje preko vrijednosti koeficijenata varijacije (*CVRMSE*) koji se određuju odnosom standardne pogreške regresije (RMSE) i prosječne vrijednosti analizirane ovisne varijable [118].

Prvi korak je utvrđivanje koje vrijednosti su abnormalne ili ekstremne. Ekstremne vrijednosti su one koje leže na više od tri vrijednosti interkvartilnog raspona (*Interquartile Range, IQR*) ispod donjeg kvartila (q_1) ili iznad gornjeg kvartila (q_3) u skupu podataka. Potrebno je utvrditi koje vrijednosti su

abnormalne ili ekstremne i pri tome se koriste sljedeći izrazi koji predstavljaju donju i gornju vanjsku ogradu (*fence*) [142]:

$$LOF = q_1 - 3 \cdot IQR \tag{5.22}$$

$$UOF = q_3 + 3 \cdot IQR \tag{5.23}$$

gdje su:

- LOF donja vanjska ograda (*Lower Outer Fence)*,
- UOF gornja vanjska ograda (*Upper Outer Fence)*,
- IQR interkvartilni raspon (*Interquartile Range*),
- q_1 donji kvartil i
- q_3 gornji kvartil.

Problem ekstremnih vrijednosti (*outliers*) može se riješiti isključivanjem istih iz modela ili izglađivanjem (umanjivanjem) tih ekstremnih vrijednosti. U ovom istraživanju nije izvršeno uklanjanje istih iz modela nego je izvršeno umanjenje ekstremnih vrijednosti razlike stvarne vrijednosti y_i i očekivane vrijednosti $\hat{y}_i$ ovisne varijable na način da iste ne prelaze unaprijed određene vrijednosti donje ili gornje vanjske ograde koje su definirane u izrazima 5.22 i 5.23. Na ovaj način ipak se zadržao utjecaj pogreške koju model generira što daje realniju sliku o modelu nego u slučajevima kada se iste u potpunosti izbace iz modela.

Zatim je izvršena korekcija razvijenih regresijskih modela na način da su negativne vrijednosti očekivane vrijednosti $\hat{y}_i$ ovisne varijable izjednačene s nulom i da je izvršeno umanjenje ekstremnih vrijednosti (*outliers*) da iste ne prelaze unaprijed određene vrijednosti donje ili gornje vanjske ograde koje su definirane u izrazima 5.22 i 5.23. U tablici 5.7 prikazana je rang lista korigiranih regresijskih modela.

Tablica 5.7 Rangiranje korigiranih regresijskih modela svedenih na ovisnu varijablu Y2,cal preko statističkih metoda RMSE i MAPE

Red. Broj	Set za razvoj (*training set*)				Set za validaciju (*validation set*)				Broj bodova
	RMSE	Oznaka modela	MAPE	Oznaka modela	RMSE	Oznaka modela	MAPE	Oznaka modela	
1	5227,5	Y0,cal,spec-2	15,37%	Y0,cal,spec-2	5421,5	Y0,cal,spec-7	12,09%	Y0,cal,spec-7	10
2	5595,1	Y0,cal,spec-1	15,65%	Y0,cal,spec-1	6308,8	Y0,cal,spec-4	13,07%	Y0,cal,spec-4	9
3	5708,5	Y0,cal-3	16,66%	Y0,cal,spec-3	6326,8	Y0,cal,spec-10	14,29%	Y0,cal,spec-10	8
4	5716,0	Y0,cal-2	17,56%	Y0,cal,spec-6	6517,8	Y0,cal-6	15,01%	Y0,cal-3	7
5	5740,2	Y1,cal,spec-2	17,69%	Y0,cal,spec-5	6681,8	Y0,cal-2	15,10%	Y0,cal-2	6
6	5801,9	Y1,cal,spec-1	18,02%	Y1,cal,spec-1	6696,6	Y0,cal,spec-3	15,36%	Y0,cal,spec-2	5
7	5870,9	Y0,cal-1	18,20%	Y0,cal,spec-4	6704,6	Y0,cal,spec-9	15,44%	Y0,cal,spec-3	4
8	5980,1	Y0,cal,spec-3	18,43%	Y1,cal,spec-2	6710,6	Y0,cal-3	15,46%	Y0,cal,spec-8	3
9	6069,5	Y1,cal-1	18,98%	Y0,cal,spec-8	6800,3	Y0,cal,spec-5	15,71%	Y0,cal,spec-9	2
10	6192,8	Y0,cal,spec-6	19,29%	Y0,cal,spec-7	7077,4	Y0,cal-1	16,98%	Y0,cal-1	1
11	6246,8	Y1,cal-2	19,31%	Y0,cal-2	7191,7	Y0,cal,spec-2	17,10%	Y0,cal,spec-5	0
12	6297,1	Y0,cal,spec-5	19,42%	Y0,cal,spec-9	7252,6	Y0,cal-5	17,36%	Y0,cal-5	0
13	6314,2	Y0,cal-4	19,48%	Y0,cal-1	7472,0	Y0,cal,spec-8	17,38%	Y0,cal,spec-6	0
14	6331,5	Y1,cal,spec-3	19,49%	Y0,cal,spec-10	7677,5	Y1,cal-1	17,52%	Y0,cal,spec-1	0
15	6383,0	Y0,cal,spec-4	19,84%	Y1,cal,spec-3	7700,2	Y0,cal-8	17,74%	Y1,cal,spec-7	0
16	6584,0	Y0,cal,spec-7	20,07%	Y0,cal-3	7723,8	Y0,cal-11	17,79%	Y1,cal,spec-5	0
17	6585,2	Y0,cal,spec-8	20,68%	Y0,cal-5	7749,0	Y0,cal-9	18,19%	Y1,cal,spec-9	0
18	6634,2	Y0,cal,spec-10	20,87%	Y1,cal,spec-4	7828,9	Y1,cal,spec-7	18,19%	Y1,cal-1	0
19	6735,5	Y1,cal,spec-5	21,17%	Y1,cal,spec-5	7897,5	Y1,cal,spec-6	18,40%	Y0,cal-6	0
20	6822,7	Y0,cal-5	21,22%	Y1,cal-1	7937,6	Y0,cal-4	18,40%	Y0,cal-8	0
21	6866,8	Y0,cal,spec-9	22,05%	Y1,cal-2	7945,9	Y1,cal-6	19,41%	Y1,cal,spec-6	0
22	6875,9	Y1,cal,spec-4	22,08%	Y0,cal-6	8108,8	Y0,cal-10	19,55%	Y1,cal,spec-2	0
23	7058,6	Y0,cal-6	22,62%	Y1,cal,spec-8	8214,4	Y1,cal-4	19,56%	Y1,cal-2	0
24	7274,1	Y1,cal,spec-7	22,70%	Y1,cal,spec-7	8232,8	Y0,cal-7	19,96%	Y1,cal,spec-4	0
25	7478,8	Y0,cal-7	23,05%	Y0,cal-4	8316,9	Y0,cal,spec-1	20,07%	Y0,cal-4	0
26	7547,9	Y1,cal,spec-6	23,23%	Y1,cal,spec-6	8325,1	Y1,cal-2	20,23%	Y1,cal,spec-3	0
27	7565,0	Y0,cal-8	23,83%	Y1,cal,spec-9	8485,5	Y1,cal-7	20,41%	Y1,cal,spec-8	0
28	7821,1	Y1,cal-3	24,88%	Y1,cal,spec-10	8503,2	Y1,cal,spec-5	20,73%	Y1,cal-6	0
29	7832,6	Y1,cal,spec-8	24,90%	Y0,cal-8	8588,9	Y1,cal-5	20,85%	Y1,cal-4	0
30	7974,5	Y1,cal-6	24,91%	Y1,cal-3	8605,3	Y1,cal,spec-9	21,86%	Y1,cal,spec-1	0
31	8095,4	Y1,cal-4	25,59%	Y2,cal,spec-1	8887,6	Y2,cal,spec-3	21,92%	Y1,cal-7	0
32	8154,5	Y2,cal,spec-1	25,67%	Y2,cal,spec-2	8929,8	Y1,cal,spec-4	22,11%	Y0,cal-9	0
33	8175,5	Y0,cal-9	26,16%	Y1,cal-4	9109,5	Y0,cal,spec-6	22,18%	Y0,cal-10	0
34	8229,9	Y1,cal,spec-9	26,62%	Y1,cal-6	9228,6	Y0,cal-12	22,35%	Y0,cal-11	0
35	8409,6	Y2,cal,spec-2	26,74%	Y1,cal-7	9259,0	Y2,cal,spec-2	23,09%	Y2,cal,spec-2	0
36	8416,0	Y1,cal-5	26,80%	Y0,cal-7	9357,3	Y1,cal,spec-2	23,32%	Y0,cal-7	0

37	8456,8	Y1,cal-7	27,50%	Y1,cal-5	9934,3	Y1,cal,spec-8	23,68%	Y1,cal-5	0
38	8515,6	Y1,cal,spec-10	27,61%	Y0,cal-9	10056,4	Y1,cal,spec-1	24,93%	Y1,cal-3	0
39	8717,8	Y1,cal-10	27,65%	Y1,cal-9	10115,6	Y1,cal-3	25,30%	Y1,cal,spec-10	0
40	8782,1	Y0,cal-10	28,00%	Y1,cal-8	10225,2	Y1,cal-9	25,96%	Y2,cal,spec-4	0
41	8865,2	Y1,cal-8	28,39%	Y2,cal,spec-4	10435,8	Y1,cal,spec-3	27,04%	Y1,cal-9	0
42	8911,7	Y2,cal,spec-4	28,55%	Y0,cal-12	10509,3	Y1,cal-8	27,98%	Y1,cal-8	0
43	8957,9	Y0,cal-11	29,21%	Y0,cal-10	10513,8	Y2,cal,spec-4	29,67%	Y2,cal,spec-1	0
44	9154,9	Y1,cal-9	30,76%	Y1,cal-10	11203,9	Y2,cal,spec-1	31,53%	Y0,cal-12	0
45	9239,8	Y0,cal-12	31,44%	Y0,cal-11	11228,3	Y1,cal,spec-10	31,78%	Y1,cal-10	0
46	9986,1	Y2,cal,spec-3	31,83%	Y2,cal,spec-3	11578,3	Y1,cal-10	34,15%	Y2,cal,spec-3	0

Analizirajući vrijednosti statističkih metoda ocjene korigiranih regresijskih modela u tablici 5.7 koji se odnose na set za razvoj modela može se uočiti kako i dalje najbolje rezultate imaju modeli bazirani na ovisnoj varijabli Y0,cal,spec, a model Y0,cal,spec-2 (neovisne varijable X1, X5, X10, X24) je prvoplasirani, a zatim slijedi model Y0,cal,spec-1 (neovisne varijable X1, X5, X10, X15, X24).

Analizirajući vrijednosti statističkih metoda ocjene korigiranih regresijskih modela u tablici 5.7 koji se odnose na set za validaciju modela može se uočiti kako je model s oznakom Y0,cal,spec-7 (neovisne varijable X1, X5, X10, X11, X20) prvoplasirani a model Y0,cal,spec-4 (neovisne varijable X1, X5, X10, X11, X19, X20) je drugoplasirani.

Zbrajajući ukupne bodove za početne (nekorigirane) i korigirane regresijske modela u tablicama 5.6 i 5.7 sljedeći modeli imaju najbolje ukupne ocjene, i to:

1. Y0,cal,spec-2,
2. Y0,cal,spec-7 i
3. Y0,cal,spec-4.

Višestruka linearna regresijska jednadžba (VLRJ) za regresijski model Y0,cal,spec-2 ima sljedeći oblik:

$$Y0,cal,spec-2 = 1382,673 + 0,100 \cdot \mathrm{X1} - 0,920 \cdot \mathrm{X5} + \tag{5.24}$$

$$+73,106 \cdot \mathrm{X10} + 72,652 \cdot \mathrm{X24} \left[kWh / m^2 god \right]$$

gdje su:

- X1 neovisna varijabla koja predstavlja broj stupanj dana grijanja (SDG),
- X5 neovisna varijabla koja predstavlja godinu izgradnje (GI),
- X10 neovisna varijabla koja predstavlja faktor oblika (f) i

- X24 neovisna varijabla koja predstavlja ukupan koeficijent izmjene topline po površini ovojnice (H').

Višestruka linearna regresijska jednadžba (VLRJ) za regresijski model Y0,cal,spec-7 ima sljedeći oblik:

$$Y0,cal,spec-7 = 1803{,}719 + 0{,}098 \cdot \mathrm{X1} - 1{,}042 \cdot \mathrm{X5} + \tag{5.25}$$

$$+76{,}509 \cdot \mathrm{X10} - 153{,}084 \cdot \mathrm{X11} + 44{,}058 \cdot \mathrm{X20} \left[kWh / m^2 god \right]$$

gdje su:

- X1 neovisna varijabla koja predstavlja broj stupanj dana grijanja (SDG),
- X5 neovisna varijabla koja predstavlja godinu izgradnje (GI),
- X10 neovisna varijabla koja predstavlja faktor oblika (f),
- X11 neovisna varijabla koja predstavlja faktor kompaktnosti (f_o) i
- X20 neovisna varijabla koja predstavlja U - vrijednost ovojnice (U).

Višestruka linearna regresijska jednadžba (VLRJ) za regresijski model Y0,cal,spec-4 ima sljedeći oblik:

$$Y0,cal,spec-4 = 1583{,}421 + 0{,}097 \cdot \mathrm{X1} - 0{,}952 \cdot \mathrm{X5} + 75{,}426 \cdot \mathrm{X10} - 155{,}891 \cdot \mathrm{X11} + \tag{5.26}$$

$$+20{,}792 \cdot \mathrm{X19} + 39{,}351 \cdot \mathrm{X20} \left[kWh / m^2 god \right]$$

gdje su:

- X1 neovisna varijabla koja predstavlja broj stupanj dana grijanja (SDG),
- X5 neovisna varijabla koja predstavlja godinu izgradnje (GI),
- X10 neovisna varijabla koja predstavlja faktor oblika (f),
- X11 neovisna varijabla koja predstavlja faktor kompaktnosti (f_o),
- X19 neovisna varijabla koja predstavlja U - vrijednost za otvore (U_o) i
- X20 neovisna varijabla koja predstavlja U - vrijednost ovojnice (U).

Osim dodijeljenih ukupnih bodova bitni kriteriji za konačnu ocjenu dobivenih regresijskih modela predstavljaju i broj korigiranih vrijednosti u regresijskim modelima. U regresijskom modelu Y0,cal,spec-2 izvršene su tri korekcije na setu za razvoj modela i tri korekcije na setu za validaciju modela. U regresijskom model Y0,cal,spec-7 izvršene su tri korekcije na setu za razvoj modela i četiri korekcije na setu za validaciju modela. U regresijskom modelu Y0,cal,spec-4 izvršene su dvije korekcije na setu za razvoj modela i pet korekcija na setu za validaciju modela.

Može se zaključiti kako modeli koji su bazirani na ovisnoj varijabli Y0,cal,spec imaju bolje rezultate na setu za razvoj modela s malim brojem korekcija u odnosu prema postavljenom kriteriju reprezentativnosti modela. Modeli bazirani na ovisnoj varijabli Y0,cal imaju bolje rezultate na setu za validaciju modela ali i veći broj korekcija na setu za razvoj modela.

Ovo istraživanje pokazuje kako modeli bazirani na specifičnim vrijednostima ovisnih varijabli (vrijednosti svedene na jedinicu korisne površine A_k) daju u ovom istraživanju bolju predikciju ukupnih proračunskih troškova isporučene toplinske energije za grijanje.

U istraživanju razvoja modela linearne regresije za predviđanje troškova izgradnje zgrada u Ujedinjenom Kraljevstvu, na temelju prikupljenih 286 skupova podataka, zaključuje se kako korištenje ukupnih (sirovih) troškova kao ovisne varijable proizvode regresijske modele koji su manje precizni od onih koji koriste ovisne varijable gdje su troškovi svedeni na jedinicu površine (trošak/m^2). Budući da regresijsko modeliranje umanjuje kvadrate pogrešaka, ono će biti pristrano prema smanjenju pogrešaka za vrlo velike projekte, gdje su pogreške najveće, a malo je vjerojatno da će model biti dobar prediktor troškova manjih projekata. Te kritike postavljaju pitanja smislenosti modela proizvedenih korištenjem ukupnih (sirovih) troškova kao prediktora za model linearne regresije [143].

U odnosu na kriterij jednostavnosti modela i mjerljivosti neovisnih varijabli izvršit će se rangiranje modela koji uključuju samo neovisne varijable koje su relativno jednostavno mjerljive. Navedeno podrazumijeva kako ove podatke prikupljaju stručne osobe koje imaju određena tehnička znanja. Jednostavne mjerljive varijable su slijedeće:

- Varijabla X1 predstavlja broj stupanj dana grijanja (SDG) koja definira klimatske uvjete, podatak koji se može odrediti iz priloga propisa i pravilnika.
- Varijabla X3 predstavlja ukupan broj korisnika (uposlenici i učenici) škole, podatak koji se dobije od uprave škole.
- Varijabla X5 predstavlja godinu izgradnje (GI), podatak koji je poznat.
- Varijabla X7 predstavlja korisnu površinu zgrade (A_k), podatak koji je poznat.
- Varijabla X10 predstavlja faktor oblika (f), podatak koji je nije poznat i potrebno je da stručna osoba izračuna na temelju površine ovojnice (A) i korisne površine (A_k).
- Varijabla X11 predstavlja faktor kompaktnosti (f_o), podatak koji je nije poznat ali se može procijeniti ili odrediti iz stručne literature ili iz dokumenta Tipologija javnih zgrada u BiH.
- Varijable X19 i X20 predstavljaju prosječne vrijednosti koeficijenata prolaska topline ''U'' (W/m^2K) za otvore i ukupnu ovojnicu. Podatci koji nisu poznati, ali se mogu procijeniti prema

razdoblju izgradnje koristeći stručnu literaturu ili dokument Tipologija javnih zgrada u BiH u kojemu se nalaze prosječne U-vrijednosti građevinskih dijelova ovojnice u odnosu na razdoblja izgradnje kao što je prikazano u tablici 3.8.

- Varijable X26 i X28 odnose se na sustav grijanja (njegovu učinkovitost) i jediničnu cijenu energenta koji se koristi. Podatci koji se mogu jednostavno procijeniti i odrediti.

Zadržavanjem samo gore navedenih neovisnih varijabli u modelu ostalo je ukupno 12 modela koji će se na isti prethodni način rangirati. U tablici 5.8 prikazana je rang lista regresijskih modela koji uključuju gore nabrojane neovisne varijable i koji predstavljaju jednostavnije regresijske modele.

Tablica 5.8 Rangiranje jednostavnijih regresijskih modela svedenih na ovisnu varijablu Y2,cal preko statističkih metoda RMSE i MAPE

Red. Broj	Set za razvoj (*training set*)				Set za validaciju (*validation set*)				Broj bodova
	RMSE	Oznaka modela	MAPE	Oznaka modela	RMSE	Oznaka modela	MAPE	Oznaka modela	
1	6421,4	Y0,cal,spec-7	18,79%	Y0,cal,spec-4	8793,0	Y0,cal,spec-7	13,28%	Y0,cal,spec-7	10
2	6437,5	Y0,cal,spec-4	19,34%	Y0,cal,spec-8	11863,2	Y0,cal,spec-4	14,66%	Y0,cal,spec-4	9
3	6653,5	Y0,cal,spec-10	19,71%	Y0,cal,spec-7	11870,4	Y0,cal,spec-10	15,36%	Y0,cal,spec-10	8
4	6732,9	Y0,cal,spec-8	19,75%	Y0,cal,spec-10	12862,0	Y2,cal,spec-3	17,01%	Y0,cal,spec-8	7
5	6790,3	Y1,cal,spec-5	21,93%	Y1,cal,spec-5	13097,2	Y2,cal,spec-2	18,66%	Y1,cal,spec-7	6
6	7646,0	Y1,cal,spec-6	23,02%	Y1,cal,spec-7	13196,7	Y1,cal,spec-7	19,55%	Y1,cal,spec-5	5
7	7768,0	Y1,cal,spec-7	23,49%	Y1,cal,spec-6	13914,3	Y2,cal,spec-4	19,85%	Y1,cal,spec-9	4
8	8372,2	Y1,cal,spec-9	23,93%	Y1,cal,spec-9	13994,1	Y0,cal,spec-8	21,02%	Y1,cal,spec-6	3
9	8430,8	Y2,cal,spec-2	25,11%	Y1,cal,spec-10	14630,7	Y1,cal,spec-9	23,71%	Y2,cal,spec-2	2
10	8911,7	Y2,cal,spec-4	25,67%	Y2,cal,spec-2	15775,3	Y1,cal,spec-5	26,54%	Y2,cal,spec-4	1
11	9075,6	Y1,cal,spec-10	28,39%	Y2,cal,spec-4	16805,7	Y1,cal,spec-6	26,69%	Y1,cal,spec-10	0
12	10138,6	Y2,cal,spec-3	31,87%	Y2,cal,spec-3	18909,3	Y1,cal,spec-10	34,93%	Y2,cal,spec-3	0

Analizirajući vrijednosti statističkih metoda ocjene regresijskih modela u tablici 5.8 može se uočiti kako je model s oznakom Y0,cal-7 (neovisne varijable X1, X5, X10, X11 i X20) je najbolje rangirani. Zbrajajući bodove sljedeća 3 modela imaju najbolje ocjene, i to:

1. Y0,cal,spec-7,
2. Y0,cal,spec-4 i
3. Y0,cal,spec-10.

Također, izvršeno je rangiranje regresijskih modela nakon što su negativne vrijednosti očekivane vrijednosti $\hat{y}_i$ ovisne varijable izjednačene s nulom i nakon što je izvršena korekcija ekstremnih vrijednosti (*outliers*) što je prikazano u tablici 5.9.

Tablica 5.9 Rangiranje korigiranih jednostavnijih regresijskih modela svedenih na ovisnu varijablu Y2,cal preko statističkih metoda RMSE i MAPE

Red. Broj	Set za razvoj (*training set*)				Set za validaciju (*validation set*)				Broj bodova
	RMSE	Oznaka modela	MAPE	Oznaka modela	RMSE	Oznaka modela	MAPE	Oznaka modela	
1	6383,0	Y0,cal,spec-4	18,20%	Y0,cal,spec-4	5421,5	Y0,cal,spec-7	12,09%	Y0,cal,spec-7	10
2	6584,0	Y0,cal,spec-7	18,98%	Y0,cal,spec-8	6308,8	Y0,cal,spec-4	13,07%	Y0,cal,spec-4	9
3	6585,2	Y0,cal,spec-8	19,29%	Y0,cal,spec-7	6326,8	Y0,cal,spec-10	14,29%	Y0,cal,spec-10	8
4	6634,2	Y0,cal,spec-10	19,49%	Y0,cal,spec-10	7472,0	Y0,cal,spec-8	15,46%	Y0,cal,spec-8	7
5	6735,5	Y1,cal,spec-5	21,17%	Y1,cal,spec-5	7828,9	Y1,cal,spec-7	17,74%	Y1,cal,spec-7	6
6	7274,1	Y1,cal,spec-7	22,70%	Y1,cal,spec-7	7897,5	Y1,cal,spec-6	17,79%	Y1,cal,spec-5	5
7	7547,9	Y1,cal,spec-6	23,23%	Y1,cal,spec-6	8503,2	Y1,cal,spec-5	18,19%	Y1,cal,spec-9	4
8	8229,9	Y1,cal,spec-9	23,83%	Y1,cal,spec-9	8605,3	Y1,cal,spec-9	19,41%	Y1,cal,spec-6	3
9	8409,6	Y2,cal,spec-2	24,88%	Y1,cal,spec-10	8887,6	Y2,cal,spec-3	23,09%	Y2,cal,spec-2	2
10	8515,6	Y1,cal,spec-10	25,67%	Y2,cal,spec-2	9259,0	Y2,cal,spec-2	25,30%	Y1,cal,spec-10	1
11	8911,7	Y2,cal,spec-4	28,39%	Y2,cal,spec-4	10513,8	Y2,cal,spec-4	25,96%	Y2,cal,spec-4	0
12	9986,1	Y2,cal,spec-3	31,83%	Y2,cal,spec-3	11228,3	Y1,cal,spec-10	34,15%	Y2,cal,spec-3	0

Analizirajući vrijednosti statističkih metoda ocjene regresijskih modela u tablici 5.9 može se uočiti kako model sa oznakom Y0,cal-4 (neovisne varijable X1, X5, X10, X11, X19 i X20) je najbolje rangirani. Zbrajajući bodove sljedeća 3 modela imaju najbolje ocjene, i to:

1. Y0,cal,spec-4,
2. Y0,cal,spec-7 i
3. Y0,cal,spec-8.

Zbrajajući ukupne bodove za početne (nekorigirane) i korigirane jednostavnije regresijske modele u tablicama 5.8 i 5.9 sljedeći modeli imaju najbolje ukupne ocjene, i to:

1. Y0,cal,spec-4,
2. Y0,cal,spec-7 i
3. Y0,cal,spec-10.

Višestruka linearna regresijska jednadžba (VLRJ) za regresijski model Y0,cal,spec-7 prikazana je u izrazu 5.26 a za regresijski model Y0,cal,spec-4 prikazana je u izrazu 5.27.

Višestruka linearna regresijska jednadžba (VLRJ) za regresijski model Y0,cal,spec-10 ima sljedeći oblik:

$$Y0,cal,spec-10 = 1821{,}628 + 0{,}098 \cdot \mathrm{X1} - 1{,}067 \cdot \mathrm{X5} + \tag{5.27}$$

$$+55{,}359 \cdot \mathrm{X10} + 39{,}090 \cdot \mathrm{X20} \left[kWh / m^2 god \right]$$

gdje su:

- X1 neovisna varijabla koja predstavlja broj stupanj dana grijanja (SDG),
- X5 neovisna varijabla koja predstavlja godinu izgradnje (GI),
- X10 neovisna varijabla koja predstavlja faktor oblika (f) i
- X20 neovisna varijabla koja predstavlja U - vrijednost ovojnice (U).

Višestruka linearna regresijska jednadžba (VLRJ) za regresijske model Y0,cal,spec-4 i Y0,cal,spec-7 nalaze se među 3 najbolja modela prema kriteriju reprezentativnosti i kriteriju jednostavnosti. U tablici 5.10 prikazan je zajednički sažetak razvijenih regresijskih modela prema vrijednosti koeficijenta determinacije (R^2) i standardne pogreške regresijskog modela (*RMSE*).

Tablica 5.10 Rang odabranih regresijskih modela prema R^2 i RMSE

Oznaka modela	R	R^2	RMSE	p-vrijed.	VLRJ
Y0,cal,spec-2	0,902	0,814	32,005	1,60E-50	Y0,cal,spec-2=1382,673+0,100*X1-0,920*X5+73,106*X10+72,652*X24
Y0,cal,spec-4	0,881	0,777	35,340	8,09E-43	Y0,cal,spec =1583,421+0,097*X1-0,952*X5+75,426*X10-155,891*X11+20,792*X19+39,351*X20
Y0,cal,spec-7	0,863	0,745	37,615	7,51E-40	Y0,cal,spec =1803,719+0,098*X1-1,042*X5+76,509*X10-153,084*X11+44,058*X20
Y0,cal,spec-10	0,845	0,715	39,673	2,0E-37	Y0,cal,spec =1821,628+0,098*X1-1,067*X5+55,359*X10+39,090*X20

Uzimajući u obzir dva kriterija (kriterij reprezentativnosti i kriterij jednostavnosti) zaključuje se kako modeli Y0,cal,spec-2, Y0,cal,spec-4, Y0,cal,spec-7 i Y0,cal,spec-10, koji su bazirani na ovisnoj varijabli Y0,cal,spec, daju najbolje rezultate s obzirom na postavljene kriterije, te će se isti u nastavku analizirati kao i neovisne varijable koje imaju najveći značaj u regresijskim modelima.

5.8 Analiza modela procjene ukupnih proračunskih troškova isporučene toplinske energije školskih zgrada u FBiH

U nastavku se detaljnije prikazuju modeli procjene ukupnih proračunskih troškova isporučene toplinske energije za grijanje ($C_{QH,del,cal}$) školskih zgrada u FBiH u funkciji razvijenih regresijskih modela koji su analizirani i najbolje rangirani u poglavlju 5.7.

Ukupni proračunski godišnji troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) određuju se preko višestrukog regresijskog modela s oznakom Y0,cal,spec-2 preko sljedeće jednadžbe:

$$C_{QH,del,cal} = (1382,673 + 0,100 \cdot \mathrm{SDG} - 0,920 \cdot \mathrm{GI} + \tag{5.28}$$

$$+73,106 \cdot f + 72,652 \cdot \mathrm{H}') \cdot (\frac{1}{\eta_{\mathrm{sys}}} \cdot A_K \cdot UC_{QH,del}) \cdot \frac{1}{1,95583} [EUR/god]$$

gdje su:

- $C_{QH,del,cal}$ godišnji proračunski trošak za isporučenu toplinsku energiju (EUR/god),
- SDG broj stupanj dana grijanja (°C·dana),
- GI godina izgradnje (god),
- f faktor oblika (-),
- H' ukupan koeficijent izmjene topline po površini ovojnice (W/m^{2}K),
- A_k korisna površina zgrade (m^2),
- η_{sys} učinkovitost sustava grijanja (-) i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Model u izrazu 5.28 pokazao se sveukupno najbolji po više pokazatelja. Neovisne varijable SDG, GI, η_{sys} i A_k relativno je jednostavno odrediti. Varijabla faktor oblika (f) predstavlja odnos ukupne površine ovojnice (A) i korisne površine (A_k), uz varijable SDG i GI, pojavljuje se u svih četiri najbolje rangiranih modela.

Ovo istraživanje pokazuje kako faktor oblika (f) ima veće značenje za procjenu potrebne toplinske energije (na visinu vrijednosti energetskog pokazatelja) od faktora kompaktnosti (f_o) koji se koristi u pravilnicima koji reguliraju zahtjeve za toplinskom zaštitom u FBiH, kao i u zemljama okruženja.

Varijablu faktora oblika (f) potrebno je izračunati. Varijabla H' predstavlja ukupan koeficijent izmjene topline po površini ovojnice koja uključuje transmisijske i ventilacijske gubitke, odnosno to je varijabla koja najbolje karakterizira toplinske gubitke jer ih sve zajednički uključuje. Ova varijabla je najzahtjevnija za proračun ili procjenu, nije ju jednostavno odrediti jer zahtijeva više parametara (površine i U-vrijednosti građevinskih dijelova ovojnice, volumen zgrade i broj izmjena zraka).

Ukupni proračunski godišnji troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) određuju se preko višestrukog regresijskog modela s oznakom Y0,cal,spec-4 preko sljedeće jednadžbe:

$$C_{QH,del,cal} = (1583{,}421 + 0{,}097 \cdot \mathrm{SDG} - 0{,}952 \cdot \mathrm{GI} + 75{,}426 \cdot \mathrm{f} - 155{,}891 \cdot \mathrm{fo} + \tag{5.29}$$

$$+ 20{,}792 \cdot \mathrm{U_O} + 39{,}351 \cdot \mathrm{U}) \cdot \left(\frac{1}{\eta_{\mathrm{sys}}} \cdot A_K \cdot UC_{QH,del}\right) \cdot \frac{1}{1{,}95583} \left[EUR/god\right]$$

gdje su:

- $C_{QH,del,cal}$ godišnji proračunski trošak za isporučenu toplinsku energiju (EUR/god),
- SDG broj stupanj dana grijanja (°C·dana),
- GI godina izgradnje (god),
- f faktor oblika (-),
- f_o faktor kompaktnosti (m^{-1}),
- U_O - vrijednost za otvore (W/m^2K),
- U - vrijednost ovojnice (W/m^2K),
- A_k korisna površina zgrade (m^2),
- η_{sys} učinkovitost sustava grijanja (-) i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Varijablu faktor oblika (f) potrebno je da stručna osoba izračuna na temelju površine ovojnice (A) i korisne površine (A_k). Varijabla faktor kompaktnosti (f_o) se može procijeniti ili odrediti na temelju raspoložive stručne literature ili dokumenta Tipologija javnih zgrada u BiH. Varijabla U predstavlja prosječnu vrijednost koeficijent prolaska topline kroz vanjsku ovojnicu i može se također procijeniti ili odrediti na temelju raspoložive stručne literature ili dokumenta Tipologija javnih zgrada u BiH. Varijabla

U_O predstavlja prosječnu vrijednost koeficijent prolaska topline kroz vanjske otvore. Može se jednostavno procijeniti na temelju stanja postojećih otvora.

Ukupni proračunski godišnji troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) određuju se preko višestrukog regresijskog modela s oznakom Y0,cal,spec-7 preko sljedeće jednadžbe:

$$C_{QH,del,cal} = (1803{,}719 + 0{,}098 \cdot \mathrm{SDG} - 1{,}042 \cdot \mathrm{GI} + 76{,}509 \cdot \mathrm{f} - 153{,}084 \cdot \mathrm{f}_0 + \\ + 44{,}058 \cdot \mathrm{U}) \cdot (\frac{1}{\eta_{\mathrm{sys}}} \cdot A_K \cdot UC_{QH,del}) \cdot \frac{1}{1{,}95583} [EUR/god] \quad (5.30)$$

gdje su:

- $C_{QH,del,cal}$ godišnji proračunski trošak za isporučenu toplinsku energiju (EUR/god),
- SDG broj stupanj dana grijanja (°C·dana),
- GI godina izgradnje (god),
- f faktor oblika (-),
- f_o faktor kompaktnosti (m^{-1}),
- U - vrijednost ovojnice (W/m^2K),
- A_k korisna površina zgrade (m^2),
- η_{sys} učinkovitost sustava grijanja (-) i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Ukupni proračunski godišnji troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) određuju se preko višestrukog regresijskog modela s oznakom Y0,cal,spec-10 preko sljedeće jednadžbe:

$$C_{QH,del,cal} = (1821{,}628 + 0{,}098 \cdot \mathrm{SDG} - 1{,}067 \cdot \mathrm{GI} + \\ + 55{,}359 \cdot \mathrm{f} + 39{,}090 \cdot \mathrm{U}) \cdot (\frac{1}{\eta_{\mathrm{sys}}} \cdot A_K \cdot UC_{QH,del}) \cdot \frac{1}{1{,}95583} [EUR/god] \quad (5.31)$$

gdje su:

- $C_{QH,del,cal}$ godišnji proračunski trošak za isporučenu toplinsku energiju (EUR/god),

- SDG broj stupanj dana grijanja (°C·dana),
- GI godina izgradnje (god),
- f faktor oblika (-),
- U - vrijednost ovojnice (W/m^{2}K),
- A_k korisna površina zgrade (m^2),
- η_{sys} učinkovitost sustava grijanja (-) i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Ukupni proračunski godišnji troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) koji se određuju preko višestrukog regresijskog modela s oznakom Y0,cal,spec-10 predstavlja najjednostavniji model za proračun godišnjih troškova za isporučenu toplinsku energiju. U regresijskom modelu Y0,cal,spec-10 izvršena je samo jedna korekcija na setu za razvoj modela i dvije korekcije na setu za validaciju modela što također predstavlja pokazatelj dobrog modela.

Analizirajući izraze od 5.28 do 5.31 koji predstavljaju modele ili funkcije za proračun ukupnih proračunskih godišnjih troškova za isporučenu toplinsku energiju ($C_{QH,del,cal}$) školskih zgrada u FBiH, koristeći statističke metode za ocjenu modela standardnu pogrešku regresije (*RMSE*) i srednju apsolutnu postotnu pogrešku (*MAPE*), u tablici 5.11 prikazano je rangiranje i zajednički sažetak u odnosu na set podataka za razvoj i prema setu za validaciju.

Tablica 5.11 Sažeti prikaz statističke ocjene prema RMSE i MAPE odabranih regresijskih modela za proračun ukupnih proračunskih godišnjih troškova za isporučenu toplinsku energiju ($C_{QH,del,cal}$)

Red. broj	Set za razvoj (*training set*)				Set za validaciju (*validation set*)			
	Oznaka modela	RMSE	Oznaka modela	MAPE	Oznaka modela	RMSE	Oznaka modela	MAPE
1	Y0,cal,spec-2	5512,6	Y0,cal,spec-2	16,40%	Y0,cal,spec-7	8793,0	Y0,cal,spec-7	13,28%
2	Y0,cal,spec-7	6421,4	Y0,cal,spec-4	18,79%	Y0,cal,spec-2	9265,8	Y0,cal,spec-4	14,66%
3	Y0,cal,spec-4	6437,5	Y0,cal,spec-7	19,71%	Y0,cal,spec-4	11863,2	Y0,cal,spec-10	15,36%
4	Y0,cal,spec-10	6653,5	Y0,cal,spec-10	19,75%	Y0,cal,spec-10	11870,4	Y0,cal,spec-2	16,56%

U odnosu na set za razvoj najbolje rangirani model procjene ukupnih proračunskih troškova isporučene toplinske energije za grijanje ($C_{QH,del,cal}$) je model u funkciji regresijskog modela Y0,cal,spec-2 gdje standardna pogreška regresije (*RMSE*) proračunskih troškova isporučene toplinske energije za grijanje

iznosi 5.512,60 EUR/god i čija je srednja postotna greška (*MAPE*) najmanja. U odnosu na set za validaciju najbolje rangirani model procjene ukupnih proračunskih troškova isporučene toplinske energije za grijanje ($C_{QH,del,cal}$) je model u funkciji regresijskog modela Y0,cal,spec-7 gdje standardna pogreška regresija (RMSE) iznosi 8.793,00 EUR/god, dok je drugoplasirani model u funkciji regresijskog modela Y0,cal,spec-2.

5.9 Analiza neovisnih varijabli u regresijskim modelima

U nastavku je izvršena analiza i ustanovljeno značenje pojedinih neovisnih varijabli u regresijskim modelima koji su najbolje rangirani u poglavlju 5.7.

Izvršena je analiza broja sudjelovanja neovisnih varijabli u 10 najboljih regresijskih modela u tablici 5.6, prema statistikama RMSE i MAPE za obadva seta (set za razvoj i set za validaciju), s ukupno 40 regresijskih modela, koja je pokazala sljedeće:

- Varijabla broj stupanj dana grijanja (SDG) pojavljuje se u svih 40 regresijskih modela ili 100%,
- Varijabla godina izgradnje (GI) građevine pojavljuje se u 90% regresijskih modela,
- Varijabla faktor oblika (f) pojavljuje se u 65% regresijskih modela,
- Varijabla ukupna površina otvora pojavljuje se u 50% regresijskih modela,
- Varijabla prosječan koeficijent prolaska topline kroz ovojnicu (U) pojavljuje se u 33% regresijskih modela,
- Varijabla ukupan koeficijent izmjene topline (H) pojavljuju se u 25% regresijskih modela,
- Varijable faktor kompaktnosti (f_0) i ukupan koeficijent izmjene topline po površini ovojnice (H') pojavljuje se u 23% regresijskih modela,
- Varijabla prosječan koeficijent prolaska topline za otvore (U_O) pojavljuje se u 20% regresijskih modela.

Ostale neovisne varijable pojavljuju se u postotku manjem od 20%. Varijable SDG, GI i faktor oblika (f) pojavljuju se u svih četiri najbolje rangiranih regresijskih modela. U najbolje rangiranom modelu procjene ukupnih proračunskih troškova isporučene toplinske energije za grijanje ($C_{QH,del,cal}$) koji je u funkciji regresijskog modela Y0,cal,spec-2, uz neovisne varijable SDG, GI i faktor oblika (f), nalazi se još varijabla H' (varijabla koja najbolje karakterizira toplinske gubitke zgrade jer uključuje karakteristike transmisijskih i ventilacijskih gubitaka).

Razvijeno je nekoliko statističkih tehnika za određivanje neovisnih varijabli koje doprinose višestruko regresijskim (multiple regresion MR) modelima. Različite tehnike za procjenu važnosti varijabli mogu potencijalno (ali ne u svim slučajevima) donijeti različite redoslijede rangiranja neovisnih varijabli.

Korištenje više tehnika pri procjeni važnosti varijable stvorit će bogatiju i cjelovitiju sliku odnosa između neovisnih varijabli i ovisne varijable. Neke od tehnika su sljedeće [129]:

- *Beta regresijski koeficijent* za neovisnu varijablu ukazuje na očekivani porast ili pad zavisne varijable u jedinicama standardnog odstupanja, s obzirom na to da se jedna neovisna varijabla povećava za jedno standardno odstupanje sa svim ostalim neovisnim varijablama koje su konstantne.
- *Nulta (početna) korelacija* je mjera koja određuje veličinu bivarijatnog odnosa između neovisne i ovisne varijable, ne uzimajući u obzir doprinose ostalih varijabli u regresijskoj jednadžbi.
- *Produkt* je mjera koja objašnjava koliko dana neovisna varijabla ima udjela u objašnjavanju varijacija ovisne varijable. Izračunava se množenjem nulte korelacije varijable s beta koeficijentom (koja uzima u obzir doprinose svih ostalih prediktora u regresijskoj jednadžbi).
- *Relativna težina* je mjera koja se izračunava dijeljenjem kvadratne nulte korelacije (r) između neovisne varijable i ovisne varijable s R^2. Relativne težine jedinstvene su kao mjera ukupnog učinka jer pružaju redoslijed doprinosa pojedinačnih neovisnih varijabli MR efektu u prisutnosti svih ostalih.
- *Koeficijent strukture* je bivarijatna korelacija između neovisne varijable i predviđene vrijednosti koja proizlazi iz MR modela. Za bilo koju neovisnu varijablu koeficijent strukture se dobije dijeljenjem bivarijatnog koeficijenta korelacije (r) između neovisne i ovisne varijable s koeficijentom višestruke korelacije R iz regresije koji sadrži sve neovisne varijable.
- *Zajednički koeficijenti* je mjera pomoću kojih se može odrediti kako je regresijski učinak podijeljen na postotke jedinstvene i zajedničke varijance.

Pretpostavlja se da su prediktori s većim beta (β) regresijskim koeficijentima važniji od ostalih prediktora s manjim koeficijentima. Ovo vrijedi kada su varijable nekorelirane, jer su u tom slučaju beta točno jednake korelaciji nultog reda između varijabli X i Y [144]. Veličina beta (β) regresijskih koeficijenata ovisi o ostalim prediktorskim varijablama koje su uključene u jednadžbu i stoga je sklona promjenama u situacijama koje uključuju različite kombinacije prediktora. Predlaže se da se beta (β)

regresijski koeficijenti i strukturni koeficijenti trebaju zajednički tumačiti kada se analiziraju rezultati regresije [145].

Prilikom razvoja modela višestruke linearne regresije izvršena je analiza neovisnih varijabli i regresijskih koeficijenata primjenom statističkih tehnika, te je izvršeno rangiranje varijabli prema doprinosu modelu. Korišteni su beta (β) regresijski koeficijenti (predstavlja doprinos svake neovisne varijable regresijskoj jednadžbi, držeći sve ostale neovisne varijable konstantnima), koeficijent linearne korelacije (r) (početna ili nulta korelacija predstavlja odnos između neovisne i ovisne varijable, bez razmatranja bilo kojih drugih neovisnih varijabli modelu), produkt (mjera koja objašnjava koliko dana neovisna varijabla ima udjela u objašnjavanju varijacija ovisne varijable), relativna težina (mjera koja određuje kako neovisne varijable doprinose zavisnoj varijabli kada je regresijski učinak podijeljen kao zajednička funkcija) i koeficijent strukture (mjera koja određuje koliko se varijance u predviđenim rezultatima za ovisnu varijablu mogu pripisati svakoj neovisnoj varijabli kada je dopušteno dijeljenje varijance između neovisnih varijabli) [129].

U tablici 5.12 prikazana je jedna analiza vrjednovanja neovisnih varijabli i njihovog doprinosa za regresijski model Y0,cal,spec-2 (neovisne varijable X1, X5, X10, X24), te je dana ocjena statističke značajnosti regresijskih koeficijenata preko p-vrijednosti.

Tablica 5.12 Analiza vrjednovanja neovisnih varijabli za regresijski model Y0,cal,spec-2

	Regresijski koeficijenti	p - vrijednost	(r) koef. linearne korelacije	(β) regresijski koef.	Produkt mjera	Relativna težina	Strukturni koef.
Konst. član	1382,673	1,71E-06					
X1 - SDG	0,100	9,7E-38	0,5563	0,666	0,370	0,380	0,616
X5 - GI	-0,920	4,27E-10	-0,4095	-0,250	0,102	0,206	-0,454
X10 - f	73,106	1,53E-31	0,3551	0,585	0,208	0,155	0,393
X24 – H’	72,652	2E-22	0,2967	0,450	0,134	0,108	0,329

Za regresijski model Y0,cal,spec-2 vrijednosti beta (β) regresijskog koeficijenta ne slijede vrijednosti koeficijenta linearne korelacije (r) pojedinih neovisnih varijabli. Međutim, vrijednosti prema pokazateljima relativne težine i strukturnog koeficijenta rangiraju važnost svake neovisne varijable u regresijskom modelu prema vrijednostima koeficijenata linearne korelacije (r). U tablicama 5.13, 5.14 i 5.15 prikazane su analize vrjednovanja neovisnih varijabli za regresijske modele Y0,cal,spec-4, Y0,cal,spec-7 i Y0,cal,spec-10.

Tablica 5.13 Analiza vrjednovanja neovisnih varijabli za regresijski model Y0,cal,spec-4

	Regresijski koeficijenti	p - vrijednost	(r) koef. linearne korelacije	(β) regresijski koef.	Produkt mjera	Relativna težina	Strukturni koef.
Konst. član	1583,421	7,11E-07					
X1 - SDG	0,097	6,57E-32	0,5563	0,644	0,358	0,398	0,631
X5 - GI	-0,952	4,08E-09	-0,4095	-0,260	0,106	0,216	-0,465
X10 - f	75,426	6,27E-20	0,3551	0,604	0,214	0,162	0,403
X11 – f_0	-155,891	1,75E-05	0,1410	-0,250	-0,035	0,026	0,160
X19 – U_o	20,792	1,91E-05	0,3207	0,184	0,059	0,132	0,364
X20 – U	39,351	2,56E-10	0,2556	0,293	0,075	0,084	0,290

Tablica 5.14 Analiza vrjednovanja neovisnih varijabli za regresijski model Y0,cal,spec-7

	Regresijski koeficijenti	p - vrijednost	(r) koef. linearne korelacije	(β) regresijski koef.	Produkt mjera	Relativna težina	Strukturni koef.
Konst. član	1803,719	9,23E-08					
X1 - SDG	0,098	3,54E-30	0,5563	0,653	0,363	0,415	0,644
X5 - GI	-1,042	1,22E-09	-0,4095	-0,280	0,115	0,225	-0,474
X10 - f	76,509	1,11E-18	0,3551	0,612	0,217	0,169	0,411
X11 – f_0	-153,084	6,83E-05	0,141	-0,250	-0,035	0,027	0,163
X20 – U	44,058	1,98E-11	0,2556	0,328	0,084	0,088	0,296

Tablica 5.15 Analiza vrjednovanja neovisnih varijabli za regresijski model Y0,cal,spec-10

	Regresijski koeficijenti	p - vrijednost	(r) koef. linearne korelacije	(β) regresijski koef.	Produkt mjera	Relativna težina	Strukturni koef.
Konst. član	1821,628	2,79E-07					
X1 - SDG	0,098	2,03E-28	0,5563	0,655	0,364	0,433	0,658
X5 - GI	-1,067	3,13E-09	-0,4095	-0,290	0,119	0,235	-0,484
X10 - f	55,359	2,68E-17	0,3551	0,443	0,157	0,176	0,420
X20 – U	39,090	4,19E-09	0,2556	0,291	0,074	0,091	0,302

Analize vrjednovanja neovisnih varijabli prema različitim statističkim tehnikama prikazanim u tablicama 5.12 do 5.15 pokazuju kako po pojedinačnom doprinosu neovisna varijabla stupanj dana grijanja (SDG) ima najveći doprinos u svim višestrukim regresijskim modelima, zatim slijedi godina izgradnje (GI) zgrade i faktor oblika (f). Ostale neovisne varijable u regresijskim modelima po svojim doprinosima smještene su iza prethodno navedene 3 varijable.

5.10 Zaključna razmatranja o modelima procjene proračunskih troškova isporučene toplinske energije školskih zgrada u FBiH

U ovom poglavlju izvršena je analiza neovisnih varijabli koje imaju utjecaj na ukupne proračunske troškove toplinske energije školskih zgrada u FBiH kao ovisne varijable, te su višestrukoregresijskom analizom razvijeni analitički izrazi ili modeli koji najbolje opisuje odnos između neovisnih i ovisne varijable i kojima je moguće procijeniti ukupne proračunske godišnje troškove za isporučenu toplinsku energiju ($C_{QH,del,cal}$) školskih zgrada u FBiH.

Izbor neovisnih varijabli osnovni je problem pri svakoj regresijskoj analizi pri čemu se nastoji zadovoljiti više kriterija kao što su reprezentativnost (najmanja pogreška) i jednostavnost modela (dostupne i lako mjerljive varijable). Na početku ovog dijela istraživanja definirane su sve moguće neovisne varijable (njih 28) i ovisne varijable (2 ovisne bazirane na stvarnim vrijednostima potrošnje i troškova toplinske energije i 6 ovisnih varijabli baziranih na proračunskim vrijednostima potrošnje i troškova toplinske energije) koje su predstavljale bazu za razvoj matematičkog model za procjenu troškova toplinske energije.

U svrhu razvoja regresijskih modela za procjenu troškova toplinske energije školskih zgrada u FBiH izvršeno je razdvajanje osnovnog seta podataka na set za razvoj modela (*training set*) i set koji služi za validaciju (*validation set*) regresijskih modela. Od ukupno 184 školske zgrade iz osnovnog (reduciranog) seta podataka nasumičnim postupkom izdvojen je set validaciju od 38 škola (20,7%), dok se u setu za razvoj modela nalaze 146 škole (79,3%).

U prvom koraku je izvršena je početna korelacijska analiza svih neovisnih i ovisnih varijabli čime su određene vrijednosti jednostavne korelacije (stupanj povezanosti) između neovisnih i ovisnih varijabli, te je izračunata statistička značajnost izražena preko p-vrijednosti (pri $p<0,05$). Varijable koje imaju manju vrijednost koeficijenta korelacije i koje nisu statistički značajne uklonjene su iz idućih analiza.

U drugom koraku izvršen je razvoj regresijskih modela (na setu za razvoj) postupkom postupne (stepwise) regresijske metode naprijed pri čemu su razvijeni višestruki linearni regresijski modeli. Pri ocjeni kvalitete regresijskih modela korištene su neke od statističkih metoda o pogreškama regresije. Preliminarna ocjena regresijskih modela izvršena je koristeći koeficijent višestruke determinacije R^2 (razmatrani su modeli čiji su vrijednosti veće od 0,70) i koeficijent varijacije regresijskog modela (CVRMSE) (usvojena je gornja granica od 30%).

Početnim razvojem regresijskih modela utvrđeno je kako su ovisne varijable Y1 (stvarna godišnja isporučena toplinska energija za grijanje) i Y2 (stvarni godišnji trošak isporučene toplinske energije) nedovoljno korelirani s neovisnim varijablama pa isti nisu pogodni za razvoj regresijskih modela i što potvrđuje energetski jaz između stvarne i potrebne (proračunske) potrošnje i troškova energije. Zbog navedenog razvoj regresijskih modela za procjenu troškova toplinske energije baziran je na proračunskim vrijednostima potrošnje i troškova toplinske energije (toplinske energije koju školske zgrade trebaju trošiti kako bi se zadovoljila toplinska ugodnost).

Kako su razvijeni regresijski modeli za ovisne varijable Y0,cal, Y0,cal,spec, Y1,cal i Y0,cal,spec bazirani na različitim jedinicama obračuna toplinske energije, i kako bi se isti mogli uspoređivati i u konačnici rangirati, izvršeni su proračuni godišnjih proračunskih troškova isporučene toplinske energije ($C_{QH,del,cal}$) na setu za razvoj i setu za validaciju kako bi se usporedilo ponašanje svih modela u istim uvjetima, te za različite setove podataka.

Za ocjenu pogreške regresijskih modela procjene godišnjih proračunskih troškova isporučene toplinske energije ($C_{QH,del,cal}$) izračunate su vrijednosti koeficijenata determinacije (R^2), standardne pogreške regresije (RMSE), koeficijenata varijacije (*CVRMSE*), srednje apsolutne postotne pogreške (*MAPE*) i srednje postotne pogreške (*MPE*).

Rangiranje regresijskih modela izvršeno je u odnosu na kriterij reprezentativnosti (najmanja pogreška regresije) i kriterij jednostavnosti modela (dostupne i lako mjerljive varijable). Najbolje rezultate općenito imaju modeli bazirani na ovisnoj varijabli Y0,cal,spec koja predstavlja vrijednosti godišnje proračunske specifične potrebne toplinske energije ($Q'_{H,nd,cal}$) svedenih na ovisnu varijablu Y2,cal odnosno na godišnji proračunski trošak isporučene toplinske energije ($C_{QH,del,cal}$). U konačnici odabrano je četiri modela (Y0,cal,spec-2, Y0,cal,spec-4, Y0,cal,spec-7 i Y0,cal,spec-10) koji u odnosu na 2 kriterija (kriterij reprezentativnosti i kriterij jednostavnosti) i 2 seta podataka (set za razvoj i set za validaciju) daju najbolje rezultate.

Ovo istraživanje pokazuje kako modeli bazirani na specifičnim vrijednostima ovisnih varijabli (vrijednosti svedene na jedinicu korisne površine A_k) daje preciznije procjene (manju pogrešku) i u konačnici bolju procjenu ukupnih proračunskih troškova isporučene toplinske energije za grijanje školskih zgrada u FBiH.

U konačnici su prikazani i analizirani modeli procjene ukupnih proračunskih troškova isporučene toplinske energije za grijanje ($C_{QH,del,cal}$) u funkciji četiriju najboljih regresijskih modela. Ukupni proračunski godišnji troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) u funkciji višestruko regresijskog modela Y0,cal,spec-2 (neovisne varijable X1, X5, X10, X24) najbolje su rangirani po kriteriju reprezentativnosti, a modeli s oznakom Y0,cal-4 (neovisne varijable X1, X5, X10, X11, X19 i X20) i Y0,cal-7 (neovisne varijable X1, X5, X10, X11 i X20), najbolje su rangirani po kriteriju jednostavnosti (s tim da se model s oznakom Y0,cal-4 nalazi među 3 najbolje rangirana i po kriteriju reprezentativnosti).

Prednosti modela procjene ukupnih godišnjih proračunskih troškova isporučene toplinske energije za grijanje ($C_{QH,del,cal}$) u funkciji regresijskih modela ogledaju se u slijedećem:

- Omogućavaju korištenje u inženjerskoj praksi da se na temelju nekoliko parametara ili varijabli procijene troškovi toplinske energije školskih zgrada u FBiH kao jedan značajan dio ukupnih godišnjih troškova uporabe i održavanja zgrada.
- Podatci o troškovima isporučene toplinske energije školskih zgrada (javne zgrade koje se financiraju proračunskim sredstvima) mogu se odrediti koristeći izgrađene regresijske modele što omogućava vlasnicima navedenih školskih zgrada početne analize, usporedbe i donošenje odluka u prioritetima obnove ili poboljšanja (smanjenje potrošnje energije i troškova istih primjenom mjera za poboljšanje energetske učinkovitosti) energetskih karakteristika.
- Jednostavniji regresijski modeli uključuju neovisne varijable kao što su broj stupanj dana grijanja (SDG), godina izgradnje (GI) i faktor oblika (f) koje se jednostavno mogu odrediti ili procijeniti.

Nedostaci i ograničenja modela procjene ukupnih godišnjih proračunskih troškova isporučene toplinske energije za grijanje ($C_{QH,del,cal}$) u funkciji regresijskih modela:

- Razvijeni regresijski modeli razvijeni su i ograničeni za školske zgrade u FBiH, i za razdoblje izgradnje do 2010. godine do kada nisu značajnije primjenjivani toplinsko izolacijski materijali u izolaciji ovojnice (većina školskih zgrada u FBiH izgrađena je u razdoblje od 1946. do 1987. godine).
- Ukupni proračunski godišnji troškovi za isporučenu toplinsku energiju ($C_{QH,del,cal}$) u funkciji najbolje rangiranog regresijskog modela Y0,cal,spec-2 prema kriteriju reprezentativnosti sadrži neovisnu varijablu H' koja predstavlja ukupan koeficijent izmjene topline po površini ovojnice koja uključuje transmisijske i ventilacijske gubitke. Ova varijabla je najzahtjevnija za proračun

ili procjenu, nije ju jednostavno odrediti jer zahtijeva više parametara (površine i U-vrijednosti građevinskih dijelova ovojnice, volumen zgrade i broj izmjena zraka).

Analiza pojedinih neovisnih varijabli u regresijskim modelima pokazala je kako se neovisne varijable broj stupanj dana grijanja (SDG), godina izgradnje (GI) i faktor oblika (f) pojavljuju se u svih četiriju najbolje rangiranih regresijskih modela. Također, analiza pojedinačnih doprinosa neovisnih varijabli u regresijskim modelima pokazuju da stupanj dana grijanja (SDG) ima najveći doprinos u svim višestrukim regresijskim modelima, zatim slijedi godina izgradnje (GI) zgrade i faktor oblika (f).

6. Zaključak i smjernice za daljnja istraživanja

6.1 Zaključak

Istraživanja pokazuju kako su troškovi životnog ciklusa dobro razrađeni u teoriji, ali pri primjeni modela u praksi nastaju poteškoće prvenstveno zbog nedostatka korisnih, pouzdanih i konzistentnih podataka. Također, postoji nedostatak istraživanja koja povezuju karakteristike zgrada s troškovima životnog ciklusa.

Ovo istraživanje je provedeno na temelju prikupljanih povijesnih podataka o karakteristikama školskih zgrada u FBiH i u kojem je izvršena analiza energetskih karakteristika i njihove povezanosti s troškovima toplinske energije, te su razvijeni novi regresijski modeli koji omogućavaju jednostavniju i bržu procjenu troškova toplinske energije. Podatci za ovo istraživanje dobiveni su iz dokumenata detaljnih energetskih pregleda (DEA) školskih zgrada za koje je provedena statistička analiza.

Istraživanjem je utvrđeno sljedeće za školske zgrade u FBiH:

- Moguće je prikupljanje povijesnih podataka o karakteristikama školskih zgrada u FBiH. Za ovo istraživanje prikupljeni su podatci za 185 školskih zgrada u FBiH što u odnosu na ukupan broj od 1.455 zgrada za obrazovanje u FBiH prema Tipologiji javnih zgrada u Bosni i Hercegovini iznosi 12,7%. Iz dokumenata detaljnih energetskih pregleda (DEA) prikupljeni su opći podatci o lokaciji, opći i geometrijski podatci o zgradama, podatci o stvarnoj potrošnji i troškovima isporučene toplinske energije za grijanje, podatci o energentima i režimu rada grijanja, podatci o stvarnoj potrošnji i troškovima električne energije, podatci o toplinskim karakteristikama građevinskih dijelova ovojnice zgrade i podatci o proračunskoj potrošnji toplinske energije za grijanje. Gore navedene kategorije podataka predstavljale su podlogu za stvaranje baze za analizu i provedbu istraživanja.
- Provedena je analiza energetskih karakteristika građevinskih dijelova ovojnice u odnosu na razdoblje izgradnje preko prosječnih U - vrijednosti svrstanih u četiri grupe, i to zidovi, podovi, stropovi i otvori. Analiza U-vrijednosti pokazuje kako iste višestruko premašuju dopuštene vrijednosti definirane prema važećim propisima što ukazuje na nedostatak slojeva toplinske izolacije i u najvećoj mjeri utječu na ukupne toplinske transmisijske gubitke. Zbog navedenog, U-vrijednosti građevinskih dijelova ovojnice predstavljaju jedno od temeljnih obilježja ili značajnih varijabli energetskih karakteristika koje utječu na potrošnju toplinske energije, a time i na troškove toplinske energije školskih zgrada u FBiH. Analiza je pokazala kako od ukupne površine ovojnice oko 30 % ovojnice čine površine vanjskih zidova i stropova, površina podova iznosi oko 27 %, a površina otvora oko 13 %.

- Analiza potrošnje toplinske i električne energije je pokazala kako od ukupne potrošnje energije udio potrošnje toplinske energije je dominantan i iznosi oko 93%, a udio potrošnje električne energije iznosi oko 7% pa su daljnje analize usmjerene na potrošnju toplinske energije za grijanje. Analiza energetskih karakteristika zgrada koja se odnosi na potrošnju toplinske energije izvršena je i usporedbom stvarne (izmjerene) i proračunske vrijednosti potrošnje isporučene toplinske energije (proračunske vrijednosti potrošnje isporučene toplinske energije predstavljaju vrijednosti dobivene proračunima prema odgovarajućim propisima kako bi se zadovolji uvjeti toplinske ugodnosti u odnosu na stvarne karakteristike zgrada). Prosječna vrijednost stvarne specifične isporučene godišnje toplinske energije za grijanje ($Q'_{H,del}$) iznosi 145,59 kWh/m^{2}god dok prosječna vrijednost proračunske specifične isporučene ($Q'_{H,del,cal}$) godišnje toplinske energije za grijanje iznosi 242,91 kWh/m^{2}god. Usporedbom stvarne i proračunske isporučene toplinske energije za grijanje može se zaključiti da stvarna potrošnja iznosi prosječno 65% potrebne i da stvarna potrošnja toplinske energije ne odražava potrebe za toplinskom energijom. Navedeni zaključak je jako bitan i ima utjecaja na razvoj regresijskih modela procjene troškova toplinske energije koji su razvijeni za proračunske vrijednosti potrošnje toplinske energije za grijanje.
- Analiza troškova potrošnje toplinske i električne energije pokazala je kako prosječni specifični godišnji trošak $C'_{QH,del}$ za isporučenu toplinsku energiju za grijanje iznosi 6,91 EUR/m^{2}god, dok prosječni specifični trošak za utrošenu električnu energiju ($C'_{E,del}$) iznosi 1,42 EUR/m^{2}god. Udio troškova toplinske energije iznosi oko 83%, a za električnu energiju udio iznosi oko 17% u ukupnim troškovima energije. Stoga su daljnje analize usmjerene na troškove toplinske energije za grijanje. Troškovi za grijanje ovise o potrošnji toplinske energije za grijanje (koja je varijabilna veličina ovisna o karakteristikama ovojnice, toplinskim gubitcima, učinkovitosti sustava grijanja, ponašanju korisnika i drugim varijablama) i jediničnom trošku energenta koji se koristi za grijanje. U odnosu na energent najniži prosječni stvarni specifični godišnji trošak energenata ($C'_{QH,del}$) za grijanje po korisnoj površini (EUR/m^{2}god) imaju školske zgrade koje se griju na energent pelet (E2) i on iznosi 2,51 EUR/m^{2}god, dok najviši prosječni stvarni specifični godišnji trošak energenata u iznosu od 10,91 EUR/m^{2}god imaju školske zgrade koje se griju na daljinsko grijanje (E4) putem gradskih toplana. Analiza troškova potrošnje toplinske i električne energije omogućava unaprjeđenje kategorizacije školskih zgrada u FBiH

identifikacijom podataka o troškovima energije koja će se temeljiti na prikupljenim povijesnim podatcima.

- Postupci proračuna energetskih karakteristika zgrada koji se odnose na potrošnju toplinske energije temelje se na korištenju propisa i inženjerskih proračuna te zahtijevaju veliku količinu ulaznih podataka pa su prikladni kada je investicijsko-tehnička dokumentacija dovoljno razrađena ili kad se provode postupci izrade detaljnih energetskih pregleda zgrada. Međutim, kako bi se u inženjerskoj praksi prilikom analize ukupnih troškova životnog ciklusa zgrada ili za potrebe upravljanja i održavanja postojećih zgrada moglo jednostavnije analizirati troškovi toplinske energije, potrebno je razvijati matematičke modele kojima se na temelju manjeg broja parametara ili karakteristika zgrada mogu s dovoljnom točnošću jednostavnije i brže procjenjivati troškovi toplinske energije zgrada. Sukladno navedenom pristupilo se razvoju novih matematičkih modela procjene potrošnje i troškova toplinske u funkciji pojedinih karakteristika (varijabli) školskih zgrada u FBiH. Najčešći statistički modeli za procjenu energetskih karakteristika zgrada su regresijski modeli koji povezuju potrošnju i troškove energije s jednom ili više varijabli.
- U razvoju regresijskih modela izvršena je analiza neovisnih varijabli koje imaju utjecaj na troškove toplinske energije školskih zgrada u FBiH i izvršeno je razdvajanje osnovnog seta podataka na set za razvoj modela (*training set*) i set koji služi za validaciju (*validation set*) regresijskih modela. U razvoju i modeliranju regresijskih modela za procjenu troškova toplinske energije korištene su proračunske vrijednosti potrošnje i troškova toplinske energije koje predstavljaju propisane potrebe za postojeće stanje energetskih karakteristika školskih zgrada u FBiH. Postupkom postupne (*stepwise*) regresijske metode unaprijed razvijeni su višestruki linearni regresijski modeli, a za ocjenu istih korištene su statističke metode. Za ocjenu i rangiranje razvijenih regresijskih modela postavljeni su kriterij reprezentativnosti i kriterij jednostavnosti.
- Razvijenim regresijskim modelima procjene troškova toplinske energije školskih zgrada u FBiH potvrđena je hipoteza ovog istraživanja da se neovisnim varijablama ili karakteristikama (godina izgradnje, korisna površina, površina ovojnice, volumen grijanog prostora, toplinske karakteristike građevinskih dijelova ovojnice, način i režim grijanja, učinkovitost sustava grijanja, energent koji se koristi za grijanje, klimatski podatci s obzirom na lokaciju zgrade) školskih zgrada mogu procijeniti ovisne varijable, odnosno troškovi toplinske energije školskih zgrada u FBiH. Ovim istraživanjem utvrđene su temeljne karakteristike ili neovisne varijable školskih zgrada u FBiH neophodne za modeliranje troškova toplinske energije.

Regresijski modeli procjene troškova toplinske energije školskih zgrada u FBiH u inženjerskoj praksi mogu se koristiti za različite potrebe:

- u fazi projektiranja kod analize i proračuna ukupnih troškova životnog ciklusa školskih zgrada u svrhu vrjednovanja varijantnih rješenja i donošenja investicijskih odluka,
- prilikom izrade detaljnih energetskih pregleda u svrhu jednostavnije procjene potrošnje toplinske energije i troškova uporabe energije, i
- za potrebe vlasnika zgrada u svrhu upravljanja istim, donošenja odluka, planova i mjera za poboljšanje energetskih karakteristika i smanjenja potrošnje i troškova energije.

Razvijeni regresijski modeli procjene troškova toplinske energije školskih zgrada u FBiH imaju osnovno ograničenje jer su isti razvijeni na temelju podataka o karakteristikama školskih zgrada u FBiH i stoga primjenjivi samo na te zgrade. Ograničenje primjene razvijenih regresijskih modela se odnosi i na osobe koje koriste iste modele i koje moraju imati određena stručna i tehnička znanja kako bi mogle prikupiti potrebne podatke i odrediti vrijednosti neovisnih varijabli koje se koriste u regresijskim modelima. Potrebno je istražiti mogu li se razvijeni regresijski modeli za procjenu ukupnih godišnjih proračunskih troškova za isporučenu toplinsku energiju školskih zgrada koristiti i u zemljama iz okruženja zbog sličnih ili istih propisa.

U odnosu na kriterij reprezentativnosti (koliko je model sposoban dobro objasniti kretanje ovisne varijable uz pomoć odabranih neovisnih varijabli) najbolji rezultat procjene ukupnih proračunskih godišnjih troškova za isporučenu toplinsku energiju ($C_{QH,del,cal}$) ima sljedeći model:

$$C_{QH,del,cal} = (1382,673 + 0,100 \cdot \mathrm{SDG} - 0,920 \cdot \mathrm{GI} + \tag{6.1}$$

$$+73,106 \cdot f + 72,652 \cdot \mathrm{H}') \cdot (\frac{1}{\eta_{\mathrm{sys}}} \cdot A_K \cdot UC_{QH,del}) \cdot \frac{1}{1,95583} [EUR/god]$$

gdje su:

- $C_{QH,del,cal}$ godišnji proračunski trošak za isporučenu toplinsku energiju (EUR/god),
- SDG broj stupanj dana grijanja (°C·dana),
- GI godina izgradnje (god),
- f faktor oblika (-),
- H' ukupan koeficijent izmjene topline po površini ovojnice (W/m^{2}K),

- A_k korisna površina zgrade (m^2),
- η_{sys} učinkovitost sustava grijanja (-) i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Za gore navedeni model u setu za razvoj modela vrijednost koeficijenta determinacije (R^2) iznosi 0,940, vrijednost standardne pogreške regresije (*RMSE*) iznosi 5.512,60 EUR-a, vrijednost koeficijenata varijacije (*CVRMSE*) iznosi 19,75%, vrijednost srednje apsolutne postotne pogreške (*MAPE*) iznosi 16,40% i srednje postotne pogreške (*MPE*) iznosi -0,22%.

Prednost ovog modela je u tome što se na temelju neovisnih varijabli mogu prilično točno procijeniti ukupni godišnji proračunski troškovi za isporučenu toplinsku energiju. Neovisne varijable SDG, GI, η_{sys} i A_k relativno je jednostavno odrediti, dok je varijablu koja predstavlja faktor oblika (f) potrebno izračunati.

Ograničenje ovog modela se odnosi na proračun varijable H' koja predstavlja ukupan koeficijent izmjene topline po površini ovojnice što uključuje transmisijske i ventilacijske gubitke, odnosno to je varijabla koja najbolje karakterizira toplinske gubitke jer ih sve zajednički uključuje. Ova varijabla je najzahtjevnija za proračun ili procjenu, nije ju jednostavno odrediti jer zahtijeva više parametara kao što su površine i U-vrijednosti građevinskih dijelova ovojnice, volumen zgrade i broj izmjena zraka kako bi se odredili transmisijski i ventilacijski gubitci.

U odnosu na kriterij jednostavnosti modela (koja se ogleda u prikupljanju neovisnih varijabli koje je jednostavno procijeniti i izmjeriti) najbolji rezultat procjene ukupnih proračunskih godišnjih troškova za isporučenu toplinsku energiju ($C_{QH,del,cal}$) ima sljedeći model:

$$C_{QH,del,cal} = (1583{,}421 + 0{,}097 \cdot \mathrm{SDG} - 0{,}952 \cdot \mathrm{GI} + 75{,}426 \cdot \mathrm{f} - 155{,}891 \cdot \mathrm{fo} + \\ + 20{,}792 \cdot \mathrm{U_O} + 39{,}351 \cdot \mathrm{U}) \cdot \left(\frac{1}{\eta_{sys}} \cdot A_K \cdot UC_{QH,del}\right) \cdot \frac{1}{1{,}95583} \left[EUR/god\right] \tag{6.2}$$

gdje su:

- $C_{QH,del,cal}$ godišnji proračunski trošak za isporučenu toplinsku energiju (EUR/god),
- SDG broj stupanj dana grijanja (°C·dana),
- GI godina izgradnje (god),

- f faktor oblika (-),
- f_o faktor kompaktnosti (m^{-1}),
- U_O - vrijednost za otvore (W/m^2K),
- U - vrijednost ovojnice (W/m^2K),
- A_k korisna površina zgrade (m^2),
- η_{sys} učinkovitost sustava grijanja (-) i
- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Za gore navedeni model u setu za razvoj modela vrijednost koeficijenta determinacije (R^2) iznosi 0,920, vrijednost standardne pogreške regresije (*RMSE*) iznosi 6.437,50 EUR-a, vrijednost koeficijenata varijacije (*CVRMSE*) iznosi 23,06%, vrijednost srednje apsolutne postotne pogreške (*MAPE*) iznosi 18,79% i srednje postotne pogreška (*MPE*) iznosi -3,45%.

Regresijski model procjene ukupnih proračunskih godišnjih troškova za isporučenu toplinsku energiju ($C_{QH,del,cal}$) s najmanje neovisnih varijabli je sljedeći:

$$C_{QH,del,cal} = (1821{,}628 + 0{,}098 \cdot \mathrm{SDG} - 1{,}067 \cdot \mathrm{GI} + \tag{6.3}$$

$$+55{,}359 \cdot \mathrm{f} + 39{,}090 \cdot \mathrm{U}) \cdot \left(\frac{1}{\eta_{sys}} \cdot A_K \cdot UC_{QH,del}\right) \cdot \frac{1}{1{,}95583} \left[EUR/god\right]$$

gdje su:

- $C_{QH,del,cal}$ godišnji proračunski trošak za isporučenu toplinsku energiju (EUR/god),
- SDG broj stupanj dana grijanja (°C·dana),
- GI godina izgradnje (god),
- f faktor oblika (-),
- U vrijednost ovojnice (W/m^2K),
- A_k korisna površina zgrade (m^2),
- η_{sys} učinkovitost sustava grijanja (-) i

- $UC_{QH,del}$ jedinični trošak energenata za grijanje po utrošenoj isporučenoj energiji (EUR/kWh).

Za gore navedeni model u setu za razvoj modela vrijednost koeficijenta determinacije (R^2) iznosi 0,913, vrijednost standardne pogreške regresije (*RMSE*) iznosi 6.653,50 EUR-a, vrijednost koeficijenata varijacije (*CVRMSE*) iznosi 23,84%, vrijednost srednje apsolutne postotne pogreške (*MAPE*) iznosi 19,75% i srednje postotne pogreške (*MPE*) iznosi -2,29%.

Prednost ovog modela je u tome što se na temelju vrlo malog broja neovisnih varijabli, koje su relativno jednostavno mjerljive, mogu izračunati ukupni godišnji proračunski troškovi za isporučenu toplinsku energiju.

6.2 Smjernice za daljnja istraživanja

Daljnja istraživanja koja se odnose na povezivanje karakteristika zgrada s troškovima životnog ciklusa, posebice s troškovima energije trebalo bi usmjeriti na:

- Testiranje razvijenih modela procijene ukupnih godišnjih proračunskih troškova za isporučenu toplinsku energiju školskih zgrada u FBiH na javnim zgradama drugih namjena u svrhu određivanja primjenljivosti razvijenih modela.
- Testiranje razvijenih modela procijene ukupnih godišnjih proračunskih troškova za isporučenu toplinsku energiju školskih zgrada u FBiH nakon primjene mjera za poboljšanje energetske učinkovitosti građevinskih dijelova ovojnice (nakon izrade toplinske izolacije vanjskih zidova, toplinske izolacije stropova prema tavanu, krovovima ili negrijanim prostorima i zamjene vanjskih otvora) i poboljšanja stupnja učinkovitosti sustava grijanja.
- Testiranje razvijenih modela procijene ukupnih godišnjih proračunskih troškova za isporučenu toplinsku energiju školskih zgrada u zemljama iz okruženja zbog sličnih ili istih propisa.
- Na temelju prikupljanih povijesnih podataka o karakteristikama školskih zgrada u FBiH razvijanje novih modela procjene troškova toplinske energije školskih zgrada u FBiH koristeći druge metode kao što su strojno učenje, ekspertni sustavi ili umjetne neuronske mreže i uspoređivanje dobivenih rezultata s razvijenim regresijskim modelima.
- Razvijanje novih modela procijene ukupnih godišnjih proračunskih troškova za isporučenu toplinsku energiju školskih zgrada u FBiH po klimatskim regijama (kontinentalni i submediteransko područje) isključujući utjecaj klimatskih karakteristika na potrošnju i troškove toplinske energije.

Literatura

[1] Leksikografski zavod Miroslav Krleža, "Tehnički Leksikon", Zagreb, ISBN 978-953-268-004-1, 2007.

[2] L. F.Cabeza, LídiaRincón, VirginiaVilariño *et al.*, "Life cycle assessment (LCA) and life cycle energy analysis (LCEA) of buildings and the building sector: A review," *Renewable and Sustainable Energy Reviews,* vol. 29, pp. 394-416, 2014. http://dx.doi.org/10.1016/j.rser.2013.08.037

[3] R. Azari, "Life Cycle Energy Consumption of Buildings; Embodied + Operational," *Sustainable Construction Technologies*, 2019.

[4] S. V. Russell-Smith, M. D. Lepech, R. Fruchter *et al.*, "Sustainable target value design: integrating life cycle assessment and target value design to improve building energy and environmental performance," *Journal of Cleaner Production*, 2014. http://dx.doi.org/10.1016/j.jclepro.2014.03.025

[5] A. H. Boussabaine, R. J. Kirkham, and R. G. Grew, "Estimating the cost of energy usage in sport centres: a comparative modelling approach," in 15th Annual ARCOM Conference, Liverpool John Moores University, 1999, pp. 481-488.

[6] B. Nicolaea, and B. George-Vlad, "Life cycle analysis in refurbishment of the buildings as interventionpractices in energy saving," *Energy and Buildings*, 2014. http://dx.doi.org/10.1016/j.enbuild.2014.10.021

[7] N. Mithraratne, B. Vale, and R. Vale, *Sustainable living: The role of whole life costs and values*, 2007.

[8] F. Rodrigues, R. Matos, A. Alves *et al.*, "Building life cycle applied to refurbishment of a traditional building from Oporto, Portugal," *Journal of Building Engineering,* vol. 17, pp. 84-95, 2018. https://doi.org/10.1016/j.jobe.2018.01.010

[9] A. Koezjakov, D. Urge-Vorsatz, W. Crijns-Graus *et al.*, "The relationship between operational energy demand and embodied energy in Dutch residential buildings," *Energy & Buildings,* vol. 2018, pp. 233-245, 2018. https://doi.org/10.1016/j.enbuild.2018.01.036

[10] P. Zancanella, P. Bertoldi, and B. Boza-Kiss, *Energy efficiency, the value of buildings and the payment default risk*, Luxembourg, 2018.

[11] S. A. Ghita, and T. Catalina, "Energy efficiency versus indoor environmental quality in differentRomanian countryside schools," *Energy and Buildings,* vol. 92, pp. 140-154, 2015. http://dx.doi.org/10.1016/j.enbuild.2015.01.049

[12] J. Kneifel, "Life-cycle carbon and cost analysis of energy efficiency measures in new commercial buildings," *Energy and Buildings,* vol. 42, pp. 333–340, 2010. doi:10.1016/j.enbuild.2009.09.011

[13] U. Desideri, D. Leonardi, L. Arcioni *et al.*, "European project Educa-RUE: An example of energy efficiency paths in educational buildings," *Applied Energy,* vol. 97, pp. 384-395, 2012. 10.1016/j.apenergy.2012.02.009

[14] R. Pacheco, J. Ordonez, and G. Martínez, "Energy efficient design of building: A review," *Renewable and Sustainable Energy Reviews,* vol. 16, pp. 3559-3573, 2012. 10.1016/j.rser.2012.03.045

[15] S. Finnegan, C. Jones, and S. Sharples, "The embodied CO 2 e of sustainable energy technologies used in buildings: A review article," *Energy & Buildings,* vol. 181, pp. 50-61, 2018. https://doi.org/10.1016/j.enbuild.2018.09.037

[16] L. Diao, Y. Sun, Z. Chen *et al.*, "Modeling energy consumption in residential buildings: A bottom-upanalysis based on occupant behavior pattern clustering and stochasticsimulation," *Energy and Buildings,* vol. 147, pp. 47-66, 2017. http://dx.doi.org/10.1016/j.enbuild.2017.04.072

[17] A. D. Angelis, F. Ascione, R. F. D. Masi *et al.*, "A Novel Contribution for Resilient Buildings. Theoretical Fragility Curves: Interaction between Energy and Structural Behavior for Reinforced Concrete Buildings," *Buildings,* vol. 10, 2020. doi:10.3390/buildings10110194

[18] D. Popescu, S. Bienert, C. Schützenhofer *et al.*, "Impact of energy efficiency measures on the economic value of buildings," *Applied Energy,* vol. 89, 2012. doi:10.1016/j.apenergy.2011.08.015

[19] J. Morrissey, and R. E. Horne, "Life cycle cost implications of energy efficiency measures in new residential buildings," *Energy and Buildings,* vol. 43, 2011. doi:10.1016/j.enbuild.2010.12.013

[20] P. Pallis, N. Gkonis, E. Varvagiannis *et al.*, "Cost effectiveness assessment and beyond: A study on energy efficiency interventions in Greek residential building stock," *Energy & Buildings,* vol. 182, pp. 1-18, 2019. https://doi.org/10.1016/j.enbuild.2018.10.024

[21] A. B. d. Vasconcelos, M. D. Pinheiro, A. Manso *et al.*, "EPBD cost-optimal methodology: Application to the thermalrehabilitation of the building envelope of a Portugueseresidential reference building," *Energy and Buildings,* vol. 111, pp. 12-25, 2016. http://dx.doi.org/10.1016/j.enbuild.2015.11.006

[22] A. M. Moncaster, F. Pomponi, K. E. Symons *et al.*, "Why method matters: Temporal, spatial and physical variations in LCA and their impact on choice of structural system," *Energy & Buildings,* vol. 173, pp. 389-398, 2018. https://doi.org/10.1016/j.enbuild.2018.05.039

[23] A. Al-Hajj, and M. W. Horner, "Modelling the running costs of buildings," *Construction Management and Economics,* vol. 16, pp. 459-470, 1998.

[24] V. Bukarica, D. Dović, Ž. H. Borković *et al.*, *Priručnik za energetske savjetnike*, Program Ujedinjenih naroda za razvoj (UNDP) u Hrvatskoj, 2008.

[25] R. J. Kirkham, "A stochastic whole life cycle cost model for a National Health Service acute care hospital building," Department of Architecture and Building Engineering, Faculty of Social and Environmental Studies, University of Liverpool, 2002.

[26] H. Krstić, "Model procjene troškova održavanja i uporabe građevina na primjeru građevina Sveučilišta Josipa Jurja Strossmayera u Osijeku," Sveučilište Josipa Jurja Strossmayera u Osijeku, Osijek, 2011.

[27] D. R. Luísa Dias Pereira, Stefano Paolo Corgnati, Manuel Gameiroda Silva, "Energy consumption in schools – A review paper," *Renewable and Sustainable Energy Reviews,* vol. 40, pp. 911-922, 2014. ttp://dx.doi.org/10.1016/j.rser.2014.08.010

[28] F. AlFaris, A. Juaidi, and F. Manzano-Agugliaro, "Improvement of efficiency through an energy management program as a sustainable practice in schools," *Journal of Cleaner Production,* vol. 135, pp. 794-805, 2016.

[29] M. Airaksinen, "Energy Use in Day Care Centers and Schools," *Energies,* vol. 4, pp. 998-1009, 2011. DOI: 10.3390/en4070998

[30] M. Aksoezen, M. Daniel, U. Hassler *et al.*, "Building age as an indicator for energy consumption," *Energy and Buildings,* vol. 87, pp. 74-86, 2015. http://dx.doi.org/10.1016/j.enbuild.2014.10.074

[31] E. H. Borgstein, R. Lamberts, and J. L. M. Hensen, "Evaluating energy performance in non-domestic buildings: A review," *Energy and Buildings*, 2016. http://dx.doi.org/10.1016/j.enbuild.2016.07.018

[32] C. F. Bandera, and G. R. Ruiz, "Towards a New Generation of Building Envelope Calibration," *Energies,* vol. 10, 2017. 10.3390/en10122102

[33] A. H. Boussabaine, R. J. Kirkham, and R. J. Grew, "Modelling total energy costs of sport centres," *Facilities,* vol. 17, no. 12/13, pp. 452-461, 1999. http://dx.doi.org/10.1108/02632779910293442

[34] V. Motuziene, A. Rogoza, V. Lapinskiene *et al.*, "Construction solutions for energy efficient single-family house based on its life cycle multi-criteria analysis: a case study," *Journal of Cleaner Production*, 2015. http://dx.doi.org/10.1016/j.jclepro.2015.08.103

[35] S. Marenjak, M. A. El-Haram, and R. M. W. Horner, "Procjena ukupnih troškova projekata u visokogradnji," *GRAĐEVINAR,* vol. 54, pp. 393-401, 2002.

[36] B. Bognar, H. Krstić, and S. Marenjak, "Analiza stvarnih i planiranih troškova održavanja i uporabe građevina," *e-GFOS,* vol. 3, pp. 85-96, 2011.

[37] T. I. F. M. Association. "What is Facility Management?," https://www.ifma.org/about/what-is-facility-management.

[38] D. G. Cotts, K. O. Roper, and R. P. Payant, *The facility management handbook*, 2009.

[39] K. S, A. Schuurmans, and E. S, *Life-cycle assessment in building and construction: a state-of-the-art report*, 2003.

[40] S. Marenjak, "Ukupni životni troškovi i održiva gradnja," 2014.

[41] H. Krstić, and S. Marenjak, "Analiza troškova održavanja i uporabe građevina," *Građevinar,* vol. 64, pp. 293-303, 2012.

[42] *A Guidebook for K-12 School System Business Officers and Facilities Managers, School Operations and Maintenance: Best Practices for Controlling Energy Costs*, 2004.

[43] M. Kishk, A. Al-Hajj, R. Pollock *et al.*, "Whole life costing in construction: a state of the art review," *RICS Research Paper Series,* vol. 4, 2003.

[44] ISO, "15686-5:2017(en)," *Buildings and constructed assets — Service life planning — Part 5: Life-cycle costing*.

[45] M. Petrović, "Diplomski rad: Upravljanje troškovima uporabe i održavanja javnog objekta," Građevinski fakultet Sveučilišta u Mostaru, 2018.

[46] *Uredba o tehničkim svojstvima koje građevine moraju zadovoljavati u pogledu sigurnosti te načina korištenja i održavanja građevina ("Službene novine Federacije BiH", br. 29/07, 51/08 i 99/14), Vlada Federacije Bosne i Hercegovine,* 2007.

[47] A. Cerić, and M. Katavić, "Upravljanje održavanjem zgrada," *GRAĐEVINAR,* vol. 53, pp. 83-89, 2000.

[48] *Zakon o gradnji u Federaciji Bosne i Hercegovine, Službene novine FBiH" broj 55/02,* 2002.

[49] *Guidelines for Life Cycle Cost Analysis, Stanford University Land and Buildings*, 2005.

[50] G. Ren, and Q. Zhang, "Benchmarking the life cycle cost management of building project," in International Conference on Intelligent Systems and Knowledge Engineering China, 2007.

[51] M. A. El-Haram, S. Marenjak, and M. W. Horner, "Development of a Generic Framework for Collecting Whole Life Cost Data for the Building Industry," *Journal of Quality in Maintenance Engineering,* vol. 9, no. 2, pp. 144-151, 2002. 10.1108/13552510210430017

[52] R. J. KIRKHAM, A. H. BOUSSABAINE, and R. G. G. S. P. SINCLAIR, "FORECASTING THE RUNNING COSTS OF SPORT AND LEISURE CENTRES," *Durability of Building Materials and Components,* vol. 8, pp. 1728-1738, 1999.

[53] P. Centar. "Ukupni životni troškovi," 8.10.2020.; https://www.pppcentar.com/wp-content/mydata/podatci.pdf.

[54] P. F. Kaming, "Implementation of life cycle costing for a commercial building: case of a residential apartment at Yogyakarta," in MATEC Web of Conferences, 2017.

[55] T. Firsani, and C. Utomo, "Analisis LCC pada Green Building Diamond Building Malaysia," *JURNAL TEKNIK ITS,* vol. 1, no. 1, 2012. 10.12962/j23373539.v1i1.1030

[56] P. F. Kaming, and J. Marliansyah, "Implementation of Life Cycle Costing: A Case of Hostel Building in Kediri, Eastern Jawa, Indonesia," *Applied Mechanics and Materials,* vol. 845, pp. 326-331, 2016. 10.4028/www.scientific.net/AMM.845.326

[57] P. F. Kaming, "Implementation of Life Cycle Costing for a University Building," *Indonesian Journal of Life Cycle Assessment and Sustainability,* vol. 1, pp. 29-38, 2016.

[58] H. Krstić, and M. Teni, "Analysis of Energy Performance and Buildings Characteristics Obtained from Croatian Energy Management Information System," *International Journal of Structural and Civil Engineering Research,* vol. 7, no. 3, pp. 252-258, 2018. doi: 10.18178/ijscer.7.3.252-258

[59] P. Marrone, P. Gori, F. Asdrubali *et al.*, "Energy Benchmarking in Educational Buildings through Cluster Analysis of Energy Retrofitting," *Energies,* vol. 11, 2018. doi:10.3390/en11030649

[60] P. Hernandez, K. Burke, and J. O. Lewis, "Development of energy performance benchmarks and building energy ratings for non-domestic buildings: An example for Irish primary schools," *Energy and Buildings,* vol. 40, pp. 249-254, 2008. doi:10.1016/j.enbuild.2007.02.020

[61] V. Butala, and P. Novak, "Energy consumption and potential energy savings in old school buildings," *Energy and Buildings,* vol. 29, pp. 241-246, 1999.

[62] L. Bellia, M. Borrelli, R. F. D. Masi *et al.*, "University building: Energy diagnosis and refurbishment design with costoptimal approach. Discussion about the effect of numerical modelling assumptions," *Journal of Building Engineering,* vol. 18, pp. 1-18, 2018. https://doi.org/10.1016/j.jobe.2018.02.017

[63] S. P. Corgnati, V. Corrado, and M. Filippi, "A method for heating consumption assessment in existing buildings: A field survey concerning 120 Italian schools," *Energy and Buildings,* vol. 40, pp. 801-809, 2008. doi:10.1016/j.enbuild.2007.05.011

[64] G. Dall'O', and L. Sarto, "Potential and limits to improve energy efficiency in space heating in existing school buildings in northern Italy," *Energy and Buildings,* vol. 67, pp. 298-308, 2013. http://dx.doi.org/10.1016/j.enbuild.2013.08.001

[65] P. Lourenc, M. D. Pinheiro, and T. Heitor, "From indicators to strategies: Key Performance Strategies forsustainable energy use in Portuguese school buildings," *Energy and Buildings,* vol. 85, pp. 212-224, 2014. http://dx.doi.org/10.1016/j.enbuild.2014.09.025

[66] A. Dimoudi, and P. Kostarela, "Energy monitoring and conservation potential in school buildings in the C0 climatic zone of Greece," *Renewable Energy,* vol. 34, pp. 289-296, 2009. 10.1016/j.renene.2008.04.025

[67] A. Thewes, S. Maas, F. Scholzen *et al.*, "Field study on the energy consumption of school buildings inLuxembourg," *Energy and Buildings,* vol. 68, no. 460-470, 2014. http://dx.doi.org/10.1016/j.enbuild.2013.10.002

[68] T. Sekkia, M. Airaksinen, and A. Saari, "Measured energy consumption of educational buildings in a Finnish city," *Energy and Buildings,* vol. 87, pp. 105-115, 2015. http://dx.doi.org/10.1016/j.enbuild.2014.11.032

[69] E. Stocker, M. Tschurtschenthaler, and L. Schrott, "Cost-optimal renovation and energy performance: Evidence fromexisting school buildings in the Alps," *Cost-optimal renovation and energy performance: Evidence fromexisting school buildings in the AlpsEmanuel,* vol. 100, pp. 20-26, 2015. http://dx.doi.org/10.1016/j.enbuild.2015.04.005

[70] J. Bowyer, *LIFE CYCLE COST ANALYSIS OF NON-RESIDENTIAL BUILDINGS*, 2013.

[71] Z. Morvaj, G. Čačić, and L. Lugarić, *Priručnik za upravljanje energijom u gradovima, kantonima i općinama*, USAID, UNDP BiH, GIZ Konsultacije za energetsku efikasnost, 2011.

[72] D. Arnautović-Aksić, M. Burazor, N. Delalić *et al.*, *Tipologija stambenih zgrada Bosne i Hercegovine*, Sarajevo, 2016.

[73] D. Agić, V. Rizvić, and S. Agić, *Pregled nacionalne situacije u pogledu energetskog siromaštva u Bosni i Hercegovini*, Centar za ekologiju i energiju, Tuzla, 2016.

[74] *Akcijski plan za energijsku efikasnost u Bosni i Hercegovini za period 2016-2018.*, 2017.

[75] *Okvirna energetska strategija Bosne i Hercegovine do 2035. godine*, 2019.

[76] *DIrektiva 2010/31/EU europskog parlamenta i vijeća od 19. svibnja 2010. o energetskoj učinkovitosti zgrada,* 2010.

[77] M. Nišandžić, *Tipologija javnih zgrada u Bosni i Hercegovini*, Razvojni program Ujedninjenih nacija (UNDP) u Bosni i Hercegovini, 2018.

[78] *Pravilnik o tehničkim zahtjevima za toplinsku zaštitu objekata i racionalnu uporabu energije (Sl. novine FBiH, br. 49/09), Federalno ministarstvo prostornog uređenja, Sarajevo,* 2009.

[79] *Pravilnik o energetskom certificiranju objekata (Sl. novine FBiH, br. 50/10), Federalno ministarstvo prostornog uređenja, Sarajevo,* 2010.

[80] *Zakon o energetskoj efikasnosti u FBiH ("Službene novine Federacije BiH", broj 22/17), Federalno ministarstvo energije, rudarstva i industrije,* 2017.

[81] *Pravilnik o minimalnim zahtjevima za energetskim značajkama zgrada (Sl. novine FBH", br. 81/2019), Federalno ministarstvo prostornog uređenja, Sarajevo,* 2019.

[82] *Uredba o provođenju energijskih audita i izdavanju energijskog certifikata ("Sl. novine FBiH", br. 87/18), Federalno ministarstva energije, rudarstva i industrije i Federalno ministarstvo prostornog uređenja,* 2019.

[83] *Pravilnik o informacijskom sistemu energijske efikasnosti FBiH ("Sl. novine FBiH", br. 2/19), Federalno ministarstvo energije, rudarstva i industrije,* 2019.

[84] Á. L. León-Rodríguez, R. Suárez, P. Bustamante *et al.*, "Design and Performance of Test Cells as an Energy Evaluation Model of Facades in a Mediterranean Building Area," *Energies,* vol. 10, 2017. doi:10.3390/en10111816

[85] T. Babaei, H. Abdi, C. P. Lim *et al.*, "A study and a directory of energy consumption data sets of buildings, Energy and Buildings," 2015.

[86] H. Krstić, and M. Teni, "ALGORITHM FOR CONSTRUCTIONAL CHARACTERISTICS DATA CLEANSING OF LARGE-SCALE PUBLIC BUILDINGS DATABASE," *WIT Transactions on The Built Environment,* vol. 175, 2019. 10.2495/HPSM180221

[87] H. Krstić, and M. Teni, "Analysis of Energy Performance and Buildings Characteristics Obtained from Croatian Energy Management Information System," *International Journal of Structural and Civil Engineering Research,* vol. 7, pp. 252-258, 2018. 10.18178/ijscer.7.3.252-258

[88] *Smjernice za provođenje energijskog pregleda za nove i postojeće objekte s jednostavnim i složenim tehničkim sistemom, Federalno ministarstvo prostornog uređenja, Sarajevo,* 2009.

[89] M. Papić, *Primijenjena statistika u MS Excelu za ekonomiste, znanstvenike i neznalice, Zoro d.o.o., Zagreb*, 2005.

[90] M. Papić, "Poslovna statistika predavanja."

[91] Ž. Pauše, *Uvod u matematičku statistiku*: Školska knjiga Zagreb, 1993.

[92] R. Ghedamsi, N. Settou, A. Gouareh *et al.*, "Modeling and forecasting energy consumption for residential buildings in Algeria using bottom-up approach," *Energy and Buildings*, 2015. http://dx.doi.org/10.1016/j.enbuild.2015.12.030

[93] D. Gajić, D. Todorović, and N. Zagora, "Reprezentativni faktori oblika stambenih kuća i zgrada Bosne i Hercegovine za određivanje referentnih energetskih razreda," in Naučno-stručni simpozijum Energetska efikasnost, Banja Luka, 2017.

[94] I. Nardi, D. Paoletti, D. Ambrosini *et al.*, "U-value assessment by infrared thermography: A comparison ofdifferent calculation methods in a Guarded Hot Box," *Energy and Buildings,* vol. 122, pp. 211-221, 2016. http://dx.doi.org/10.1016/j.enbuild.2016.04.017

[95] G. Ficco, F. Iannetta, E. Ianniello *et al.*, "U-value IN-SITU measurement for energy diagnosis of existing buildings, Energy andBuildings," 2015.

[96] Institut za standardizaciju BiH, "BAS EN ISO 13789:2007, Toplotne karakteristike građevina-Koeficijenti prenošenja toplote transmisijom i ventilacijom - Metode proračuna," 2009.

[97] "Detaljni energetski pregled Javna ustanova O. Š. ''Srednje'' Ilijaš, Ceteor, Sarajevo," 2015.

[98] Institut za standardizaciju BiH, "BAS EN ISO 13790:2008, Energetska svojstva građevina - Proračun energije potrebne za grijanje i hlađenje prostora," 2008.

[99] H. Krstić, and M. Teni, “Review of Methods for Buildings Energy Performance Modelling,” in Materials Science and Engineering, 2017.

[100] *Prilog F pravilnika o minimalnim zahtjevima za energetskim značajkama zgrada (Sl. novine FBH", br. 81/2019), Federalno ministarstvo prostornog uređenja, Sarajevo,* 2019.

[101] "Detaljni energetski pregled Javna ustanova O. Š. ''Fahrudin Fahro Baščelija'' Goražde, Ceteor, Sarajevo," 2013.

[102] "Izvještaj o detaljnom energetskom pregledu JU OŠ „Mirsad Prnjavorac“ u Vogošći, Mašinski fakultet, Sarajevo," 2016.

[103] "Detaljni energetski pregled Javna ustanova O. Š. ''Musa Ćazim Ćatić'' Kladanj, Ceteor, Sarajevo," 2015.

[104] "Detaljni energetski pregled Javna ustanova O. Š. ''Ključ'' Ključ, Ceteor Sarajevo, Euroing Bihać," 2016.

[105] "Detaljni energetski pregled O. Š. ''Todorovo'' Velika Kladuša, Zagrebinspekt, Mostar," 2016.

[106] "Detaljni energetski pregled O. Š. ''Ivana Mažuranića'' Posušje, Zagrebinspekt, Mostar," 2016.

[107] "Detaljni energetski pregled O. Š. ''Kardinala Stepinca'' Neum, Građevinski fakultet Sveučilišta u Mostaru," 2016.

[108] E. Burman, D. Mumovic, and J. Kimpian, “Towards measurement and verification of energy performance under the framework of the European directive for energy performance of buildings,” *Energy,* vol. 77, pp. 153-163, 2014. http://dx.doi.org/10.1016/j.energy.2014.05.102

[109] "Summary of Audits Performed on CarbonBuzz by the UCL Energy Institute," U. E. Institute, ed., 2013.

[110] C. Demanuele, T. Tweddell, and M. Davies, “Bridging the gap between predicted and actual energy performance in schools,” in World Renewable Energy Congress XI, Abu Dhabi, UAE, 2010.

[111] N. Harbaš, and A. Husika, "Troškovno-optimalni nivoi ulaganja u mjere energijske efikasnosti stambenih i javnih zgrada."

[112] S. Brandt, *Data Analysis: Statistical and Computational Methods for Scientists and Engineers*, Fourth Edition ed., 2014.

[113] A. A. A. Whyte, “Estimation of life-cycle costs of buildings: regression vs artificial neural network,” *Built Environment Project and Asset Management,* vol. 16, no. 1, pp. 30-43, 2016. http://dx.doi.org/10.1108/BEPAM-08-2014-0035

[114] N. Gaitani, C. Lehmann, M. Santamouris *et al.*, “Using principal component and cluster analysis in the heating evaluation of the school building sector,” *Applied Energy,* vol. 87, pp. 2079-2086, 2010. 10.1016/j.apenergy.2009.12.007

[115] N. Hrovatin, and J. Zorić, “Determinants of energy-efÞcient home retroÞts in Slovenia: The role of information sources,” *Energy & Buildings*, 2018. https://doi.org/10.1016/j.enbuild.2018.09.029

[116] G. Smhit, “Step awey from stepwise,” *Journal of Big Data*, 2018. https://doi.org/10.1186/s40537-018-0143-6

[117] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning: Data Minning, Inference, and Prediction*, 2009.

[118] R. Sailee, “Exploration of Variable Importance and Variable selection techniques in presence of correlated variables,” Rochester Institute of Technology, 2019.

[119] J. H. Scofield, “ENERGY STAR Building Benchmarking Scores: Good Idea, Bad Science,” *ACEEE Summer Study Energy Efficiency in Buildings,* vol. 4, pp. 267-282, 2014.

[120] R. L. B. Draelos, "Best Use of Train/Val/Test Splits, with Tips for Medical Data," *Machine Learning and Medicine*, 2019.

[121] R. K. Jain, K. M. Smith, P. J. Culligan *et al.*, “Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal

and spatial monitoring granularity on performance accuracy," *Applied Energy,* vol. 123, pp. 168-178, 2014. http://dx.doi.org/10.1016/j.apenergy.2014.02.057

[122] C. E. Kontokosta, and C. Tull, "A data-driven predictive model of city-scale energy use in buildings," *Applied Energy,* vol. 197, pp. 303-317, 2017. http://dx.doi.org/10.1016/j.apenergy.2017.04.005

[123] G.-H. Kim, S.-H. An, and K.-I. Kang, "Comparison of construction cost estimating models based on regression analysis, neural networks, and case-based reasoning," *Building and Environment,* vol. 39, pp. 1235-1242, 2004. 10.1016/j.buildenv.2004.02.013

[124] V. B. Dongre, R. S. Gandhi, A. Singh *et al.*, "Comparative efficiency of artificial neural networks and multiple linear regression analysis for prediction of first lactation 305-day milk yieldin Sahiwal cattle," *Livestock Science,* vol. 147, pp. 192-197, 2012. http://dx.doi.org/10.1016/j.livsci.2012.04.002

[125] A. M. Flitman, "TOWARDS ANALYSING STUDENT FAILURES: NEURAL NETWORKS COMPARED WITH REGRESSION ANALYSIS AND MULTIPLE DISCRIMINANT ANALYSIS," *Computers Ops Res.,* vol. 24, 1997.

[126] M. Han, Z. Wang, and X. Zhang, "Modeling Using a Gaussian Mixture Model and Expectation-Maximization Algorithm," *Buildings,* vol. 11, 2021. https://doi.org/10.3390/buildings11010030

[127] N. S. Software, "Stepwise Regression," Chapter 311.

[128] L. Wasserman, *All of Statistics - A Concise Course in Statistical Inference*: Springer Science, 2004.

[129] L. L. Nathans, F. L. Oswald, and K. Nimon, "Interpreting Multiple Linear Regression: A Guidebook of Variable Importance," *Practical Assessment, Research & Evaluation,* vol. 17, no. 9, 2012.

[130] M. Udovičić, K. Baždarić, L. Bilić-Zulle *et al.*, "Što treba znati kada izračunavamo koeficijent korelacije?," *Biochemia Medica,* vol. 17, 2007.

[131] J. I. Daoud, "Multicollinearity and Regression Analysis," *Journal of Physics: Conference Series,* vol. 949, 2017. 10.1088/1742-6596/949/1/012009

[132] D. Disatnik, and L. Sivan, "The multicollinearity illusion in moderated regression analysis," *Springer Science*, 2014. 10.1007/s11002-014-9339-5

[133] E. R. Mansfield, and B. P. Helms, "Detecting Multicollinearity," *The American Statistician,* vol. 36:3a, 2012. 10.1080/00031305.1982.10482818

[134] G. R. Small, and R. Wong, "The Validity of Forecasting," in Pacific Rim Real Estate Society International Conference Christchurch, 2002.

[135] M. G. Sobol, "Validation Strategies for Multiple Regression Analysis: Using the Coefficient of Determination," *Interfaces,* vol. 21, no. 6, pp. 106-120, 1991.

[136] Dataquest. "Tutorial: Understanding Regression Error Metrics in Python," 11.3., 2021; https://www.dataquest.io/blog/understanding-regression-error-metrics/.

[137] I. Lulić, "Završni rad: Uporaba metode regresijske analize u rješavanju problema vezanih za inženjersku praksu," Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, 2014.

[138] A. Cacabelos, P. Eguía, L. Febrero *et al.*, "Development of a new multi-stage building energy model calibrationmethodology and validation in a public library," *Energy and Buildings,* vol. 146, pp. 182-199, 2017. http://dx.doi.org/10.1016/j.enbuild.2017.04.071

[139] Q. Li, G. Augenbroe, and J. Brown, "Assessment of linear emulators in lightweight Bayesian calibration ofdynamic building energy models for parameter estimation and performance prediction," *Energy and Buildings,* vol. 124, pp. 194-202, 2016. http://dx.doi.org/10.1016/j.enbuild.2016.04.025

[140] D. A. HENDERSON, and D. R. DENISON, "STEPWISE REGRESSION IN SOCIAL AND PSYCHOLOGICAL RESEARCH," *Psychological Reports,* vol. 64, pp. 251-257, 1989.

[141] I. M. M. Ghani, and S. Ahmad, *Procedia Social and Behavioral Sciences,* vol. Stepwise Multiple Regression Method to Forecast Fish Landing, no. 8, pp. 549-554, 2010. 10.1016/j.sbspro.2010.12.076

[142] E. S. Handbook. "What are outliers in the data?," 6.11., 2021.

[143] D. J. Lowe, M. W. Emsley, and A. Harding, “Predicting Construction Cost Using Multiple Regression Techniques,” *Journal of Construction Engineering and Management,* vol. 132, no. 7, pp. 750-758, 2006. 10.1061/(ASCE)0733-9364(2006)132:7(750)

[144] K. F. Nimon, and F. L. Oswald, “Understanding the Results of Multiple Linear Regression: Beyond Standardized Regression Coefficients,” *Organizational Research Methods,* vol. 16, 2013. 10.1177/1094428113493929

[145] T. Courville, and B. Thompson, “USE OF STRUCTURE COEFFICIENTS IN PUBLISHED MULTIPLE REGRESSION ARTICLES: β IS NOT ENOUGH,” *Educational and Psychological Measurement,* vol. 61, no. 2, pp. 229-248, 2001.

Prilozi

Prilog 1 – Ulazni podatci o karakteristikama školskih zgrada u FBiH iz uzorka

Prilog 2 – Korelacijska analiza neovisnih i ovisnih varijabli ulaznog seta podataka školskih zgrada u FBiH iz uzorka

Prilog 1 – Ulazni podatci o karakteristikama školskih zgrada u FBiH iz uzorka

R. br.	Šifra-rad	Naziv škole	Grad	Srednja godišnja temp.	Srednja mjesečna temperatura u sezoni grijanja	Broj stupanj dana u sezoni grijanja	ISSE - šifra	Županija	Broj uposlenih
		Naziv/grad/županija							
1	BPK-GOR-01	OŠ "Fahrudin Fahro Baščelija"	Goražde	9,8	4,6	2959	BA-73000-0004-1	BPK	64
2	BPK-GOR-02	OŠ "Mehmedalija Mak Dizdar" Vitkovići	Goražde	9,8	4,6	2959	BA-73000-0014-1	BPK	59
3	BPK-GOR-03	OŠ "Hasan Turčalo brzi" Ilovača	Goražde	9,8	4,6	2959	-	BPK	21
4	BPK-PRA-01	OŠ Prača	Prača	9,8	4,6	2959	-	BPK	13
5	KS-SAR-01	OŠ "Fatima Gunić"	Sarajevo	9,5	4,5	2992	BA-71160-0006-1	KS	72
6	KS-SAR-02	OŠ "Aleksa Šantić"	Sarajevo	9,5	4,5	2992	BA-71160-0001-1	KS	70
7	KS-SAR-03	OŠ "Mirsad Prnjavorac"	Vogošća	9,5	4,5	2992	BA-71320-0001-1	KS	75
8	KS-SAR-04	OŠ "Hamdija Kreševljaković"	Sarajevo	9,5	4,5	2992	BA-71140-0025-1	KS	45
9	KS-SAR-05	OŠ "Hrasno"	Sarajevo	9,5	4,5	2992	BA-71120-0004-1	KS	63
10	KS-SAR-06	OŠ "Malta"	Sarajevo	9,5	4,5	2992	BA-71120-0028-1	KS	60
11	KS-SAR-07	"Druga osnovna škola" Hrasnica	Ilidža	9,5	4,5	2992	BA-71210-0025-1	KS	63
12	KS-SAR-08	OŠ "9. maj" Pazarić	Hadžići	9,5	4,5	2992	BA-71240-0007-1	KS	48
13	KS-SAR-09	OŠ "Čengić Vila I"	Sarajevo	9,5	4,5	2992	BA-71120-0033-1	KS	78
14	KS-SAR-10	OŠ "Hilmi ef. Šarić"	Hadžići	9,5	4,5	2992	BA-71240-0008-1	KS	53
15	KS-SAR-11	OŠ "Vladislav Skarić"	Sarajevo	9,5	4,5	2992	BA-71103-0049-1	KS	70
16	KS-SAR-12	"Šesta osnovna škola" Ilidža	Ilidža	9,5	4,5	2992	BA-71210-0033-1	KS	47
17	KS-SAR-13	OŠ "Behaudin Selmanović"	Sarajevo	9,5	4,5	2992	BA-71160-0021-1	KS	42
18	KS-SAR-14	OŠ "Edhem Mulabdić"	Sarajevo	9,5	4,5	2992	-	KS	35
19	KS-SAR-15	III Gimnazija u Sarajevu	Sarajevo	9,5	4,5	2992	-	KS	65
20	KS-SAR-16	OŠ "Zahim Bručija"	Vogošća	9,5	4,5	2992	-	KS	50
21	KS-SAR-17	Željeznički školski centar u Sarajevu	Sarajevo	9,5	4,5	2992	-	KS	48
22	KS-SAR-18	OŠ "Mula Mustafa Bašeskija"	Sarajevo	9,5	4,5	2992	-	KS	51
23	KS-SAR-19	OŠ "Izet Šabić"	Vogošća	9,5	4,5	2992	-	KS	40
24	KS-SAR-20	OŠ "Isak Samokovlija"	Sarajevo	9,5	4,5	2992	-	KS	38
25	KS-SAR-21	OŠ "Pofalići"	Sarajevo	9,5	4,5	2992	-	KS	25
26	KS-SAR-22	Srednja Medicinska škola Jezero	Sarajevo	9,5	4,5	2992	-	KS	42
27	KS-SAR-23	Srednja škola za okoliš i drvni dizajn	Sarajevo	9,5	4,5	2992	-	KS	44
28	KS-SAR-24	Srednja zubotehnička škola	Sarajevo	9,5	4,5	2992	-	KS	58
29	KS-SAR-25	OŠ "Musa Ćazim Ćatic"	Sarajevo	9,5	4,5	2992	-	KS	57
30	KS-SAR-26	OŠ "Osman Nakaš"	Sarajevo	9,5	4,5	2992	-	KS	47
31	KS-SAR-27	OŠ "Skender Kulenović"	Sarajevo	9,5	4,5	2992	-	KS	75
32	KS-SAR-28	OŠ "Meša Selimović"	Sarajevo	9,5	4,5	2992	-	KS	54
33	KS-SAR-29	Peta osnovna škola Ilidža	Ilidža	9,5	4,5	2992	-	KS	70
34	KS-SAR-30	Srednja elektrotehnička škola Sarajevo	Sarajevo	9,5	4,5	2992	-	KS	67
35	KS-ILI-01	OŠ "Srednje"	Ilijaš	9,5	4,5	2992	-	KS	44
36	KS-ILI-02	OŠ "Hasim Spahić"	Ilijaš	9,5	4,5	2992	-	KS	64
37	KS-ILI-03	OŠ "Podlugovi"	Ilijaš	9,5	4,5	2992	-	KS	50
38	TK-SRE-01	OŠ "Duboki Potok"	Srebrenik	10,0	4,9	2843	BA-75350-0015-1	TK	57
39	TK-SRE-02	OŠ "Rapatnica"	Srebrenik	10,0	4,9	2843	BA-75350-0006-1	TK	46
40	TK-SRE-03	Prva osnovna škola Srebrenik	Srebrenik	10,0	4,9	2843	-	TK	89
41	TK-SRE-04	Druga osnovna škola Srebrenik	Srebrenik	10,0	4,9	2843	-	TK	56
42	TK-SRE-05	OŠ "Tinja"	Srebrenik	10,0	4,9	2843	-	TK	43
43	TK-SRE-06	OŠ ''Sladna''	Srebrenik	10,0	4,9	2843	-	TK	38
44	TK-SRE-07	OŠ ''Podorašje''	Srebrenik	10,0	4,9	2843	-	TK	43
45	TK-LUK-01	OŠ "Lukavac Grad"	Lukavac	10,0	4,9	2843	BA-75300-0011-1	TK	65
46	TK-LUK-02	OŠ ''Lukavac Mjesto''	Lukavac	10,0	4,9	2843	-	TK	52
47	TK-LUK-03	OŠ "Dobošnica"	Lukavac	10,0	4,9	2843	-	TK	41
48	TK-LUK-04	OŠ "Gnojnica"	Lukavac	10,0	4,9	2843	-	TK	42
49	TK-ZIV-01	OŠ "Gračanica"	Živinice	10,0	4,9	2843	-	TK	63
50	TK-ZIV-02	OŠ "Đurđevik"	Živinice	10,0	4,9	2843	-	TK	68
51	TK-BAN-01	Mješovita srednja škola Banovići	Banovići	10,0	4,9	2843	-	TK	95
52	TK-KLA-01	Mješovita srednja škola "Musa Ćazim Ćatić"	Kladanj	10,0	4,9	2843	-	TK	44
53	TK-CEL-01	Mješovita srednja škola Čelić	Čelić	10,0	4,9	2843	-	TK	46
54	TK-CEL-02	OŠ "Vražići"	Čelić	10,0	4,9	2843	-	TK	39

		Naziv/grad/županija							Broj uposlenih/korisnika	
R. br.	Šifra-rad	Naziv škole	Grad	Srednja godišnja temp.	Srednja mjesečna temperatura u sezoni grijanja	Broj stupanj dana u sezoni grijanja	ISSE - šifra	Županija	Broj uposlenih	Broj učenika
55	TK-GRA-01	OŠ ''Edhem Mulabdić''	Gradačac	10,0	4,9	2843	-	TK	47	359
56	TK-SAP-01	OŠ ''Sapna''	Sapna	10,0	4,9	2843	-	TK	68	743
57	TK-KAL-01	OŠ ''Rainici Gornji''	Kalesija	10,0	4,9	2843	-	TK	63	638
58	TK-TUZ-01	OŠ "Jala"	Tuzla	10,0	4,9	2843	-	TK	43	408
59	SBK-NT-01	Osnovna glazbena škola "Jakova Gotovca"	Novi Travnik	10,1	5,1	2825	-	SBK	17	112
60	SBK-NT-02	Mješovita srednja škola Novi Travnik	Novi Travnik	10,1	5,1	2825	-	SBK	50	472
61	SBK-BUG-01	III i I OŠ Jaklić Bugojno	Bugojno	10,1	5,1	2825	-	SBK	73	610
62	SBK-USK-01	OŠ Uskoplje	Uskoplje	10,1	5,1	2825	-	SBK	43	348
63	SBK-USK-02	OŠ Voljevac	Uskoplje	10,1	5,1	2825	-	SBK	30	210
64	SBK-DF-01	Mješovita srednja škola Donji Vakuf	Donji Vakuf	10,1	5,1	2825	-	SBK	30	210
65	K10-TG-01	OŠ Ivana Mažuranića	Tomislavgrad	8,9	4,0	3095	-	K10	136	963
66	K10-TG-02	OŠ fra Mije Čujića	Tomislavgrad	8,9	4,0	3095	-	K10	15	90
67	K10-LIV-01	Srednja strukovna škola Silvija S. Kranjčevića	Livno	8,9	4,0	3095	-	K10	74	600
68	K10-KUP-01	Srednja škola Kupres	Kupres	8,9	4,0	3095	-	K10	46	368
69	PK-ORA-01	OŠ fra Ilija Starčević Tolisa	Orašje	11,5	5,8	2639	-	PK	50	375
70	PK-ORA-02	OŠ Stjepan Radić	Orašje	11,5	5,8	2639	-	PK	30	162
71	PK-ODZ-01	OŠ Vladimira Nazora	Odžak	11,5	5,8	2639	-	PK	53	494
72	USK-BUZ-01	OŠ "Bužim"	Bužim	10,6	5,5	2656	BA-77245-0002-1	USK	134	1731
73	USK-BUZ-02	OŠ "Konjodor" Bužim	Bužim	10,6	5,5	2656	BA-77245-0006-1	USK	33	253
74	USK-BK-01	Prva osnovna škola	Bosanska Krupa	10,6	5,5	2656	-	USK	72	426
75	USK-BK-02	Druga osnovna škola	Bosanska Krupa	10,6	5,5	2656	BA-77240-0011-1	USK	37	471
76	USK-BK-03	Mješovita srednja škola "Safet Krupić"	Bosanska Krupa	10,6	5,5	2656	BA-77240-0030-1	USK	71	636
77	USK-BK-04	O.Š. Jezerski	Bosanska Krupa	10,6	5,5	2656	-	USK	45	300
78	USK-BK-05	OŠ ''Otoka''	Bosanska Krupa	10,6	5,5	2656	-	USK	49	578
79	USK-KLJU-01	OŠ ''Ključ''	Ključ	10,1	4,9	2809	-	USK	51	504
80	USK-KLJU-02	JU Mješovita srednja škola Ključ	Ključ	10,1	4,9	2809	BA-79280-0007-1	USK	30	300
81	USK-SM-01	OŠ "5. oktobar"	Sanski Most	10,1	4,9	2809	BA-79260-0008-1	USK	58	785
82	USK-SM-02	Mješovita srednja škola / Gimnazija	Sanski Most	10,1	4,9	2809	-	USK	80	718
83	USK-SM-03	Srednja poljoprivredna škola ''Sanus Futurum''	Sanski Most	10,1	4,9	2809	-	USK	30	200
84	USK-CAZ-01	OŠ ''Stijena''	Cazin	10,6	5,5	2656	-	USK	70	805
85	USK-CAZ-02	OŠ "Gornja Koprivna"	Cazin	10,6	5,5	2656	BA-77220-0019-1	USK	51	465
86	USK-CAZ-03	OŠ ''Slatina''	Cazin	10,6	5,5	2656	-	USK	11	95
87	USK-CAZ-04	I i II srednja škola Cazin	Cazin	10,6	5,5	2656	-	USK	71	774
88	USK-VK-01	OŠ ''1. Mart'' Vrnograč	Velika Kladuša	10,6	5,5	2656	-	USK	54	558
89	USK-VK-02	OŠ '25. Novembar''	Velika Kladuša	10,6	5,5	2656	-	USK	58	684
90	USK-VK-03	OŠ "Todorovo" Velika Kladuša	Velika Kladuša	10,6	5,5	2656	BA-77230-0014-1	USK	30	220
91	USK-VK-04	Srednja škola dr. Husein Džanić, I Srednja Škola	Velika Kladuša	10,6	5,5	2656	-	USK	86	948
92	USK-BIH-01	O.Š. Harmani II	Bihać	10,6	5,5	2656	-	USK	77	853
93	USK-BIH-02	MSŠ elektrotehnička i drvoprerađivačka Bihać	Bihać	10,6	5,5	2656	-	USK	50	1000
94	USK-BIH-03	OŠ ''Kamenica''	Bihać	10,6	5,5	2656	-	USK	35	283
95	USK-BIH-04	OŠ ''Gornje prekounje Ripač''	Bihać	10,6	5,5	2656	-	USK	80	498
96	ZDK-TES-01	OŠ "Džemal Bijedić" Miljanovci	Tešanj	10,1	5,1	2825	-	ZDK	47	418
97	ZDK-TES-02	OŠ "Gazi Ferhad-beg''	Tešanj	10,1	5,1	2825	-	ZDK	35	318
98	ZDK-TES-03	OŠ "Rašid Kadić" Krndija	Tešanj	10,1	5,1	2825	-	ZDK	52	492
99	ZDK-TES-04	OŠ "Rašid Kadić" PŠ Džemilić Planje	Tešanj	10,1	5,1	2825	-	ZDK	29	224
100	ZDK-TES-05	OŠ "Abdulvehab Ilhamija", Kološević Jelah	Tešanj	10,1	5,1	2825	-	ZDK	44	292
101	ZDK-TES-06	Gimnazija Musa Ćazim Ćatić, Srednja tehnička	Tešanj	10,1	5,1	2825	-	ZDK	221	1997
102	ZDK-USO-01	MSŠ Stjepan Radić, Žabljak	Usora	10,1	5,1	2825	-	ZDK	58	650
103	ZDK-USO-02	OŠ ''Ivan fra Frano Jukić'', Sivša	Usora	10,1	5,1	2825	-	ZDK	32	210
104	ZDK-DOB-01	OŠ ''21 Mart'', Matuzići	Doboj Jug	10,1	5,1	2825	-	ZDK	38	225
105	ZDK-MAG-01	JU'' Prva osnovna škola'' Maglaj	Maglaj	10,1	5,1	2825	BA-71250-0007-1	ZDK	95	722
106	ZDK-MAG-02	OŠ "Maglaj"	Maglaj	10,1	5,1	2825	BA-74250-0006-1	ZDK	87	937
107	ZDK-MAG-03	MSŠ Maglaj i gimnazija Edhem Mulabdić	Maglaj	10,1	5,1	2825	BA-74250-0003-1	ZDK	50	560
108	ZDK-ZEP-01	SMŠ Žepče	Žepče	10,1	5,1	2825	-	ZDK	142	847

		Naziv/grad/županija							Broj uposlenih/korisnika		Opći podatci o zgradi										
R. br.	Šifra-rad	Naziv škole	Grad	Srednja godišnja temp.	Srednja mjesečna temperatura u sezoni grijanja	Broj stupanj dana u sezoni grijanja	ISSE - šifra	Županija	Broj uposlenih	Broj učenika	Škola sa dvoranom (DA/NE)	Regija (Sjever/Jug)	Godina izgradnje	Razdoblje izgradnje prema tipologiji javnih zgrada	Starost zgrade u odnosu na 2020. godinu	Godina značajne rekonstrukcije i obnove	Godina izrade DEA	Izrađivač DEA	Godina energetske obnove	Tlocrtna bruto površina	Broj etaža
109	ZDK-ZEP-02	OŠ "Begov Han''	Žepče	10,1	5,1	2825	-	ZDK	43	380	NE	Sjever	1979	4	41	-	2017	Zagreb inspekt	*	-	P+1
110	ZDK-ZAV-01	OŠ "Kovači"	Zavidovići	10,1	5,1	2825	BA-71250-0007-1	ZDK	50	462	DA	Sjever	1950	2	70	-	2016	Ceteor	2018	2775,3	P+1
111	ZDK-ZAV-02	OŠ "Gostović"	Zavidovići	10,1	5,1	2825	-	ZDK	42	339	DA	Sjever	1962	2	58	-	2016	Ceteor	*	-	P+1
112	ZDK-ZAV-03	OŠ "Hajderovići"	Zavidovići	10,1	5,1	2825	-	ZDK	36	313	DA	Sjever	1964	2	56	-	2016	Ceteor	*	-	Po+P+1
113	ZDK-ZAV-04	Gimnazija ''Rizad Odžečkić''	Zavidovići	10,1	5,1	2825	-	ZDK	50	500	DA	Sjever	1973	3	47	-	2014	Enova	*	-	P+2
114	ZDK-ZEN-01	OŠ "Musa Ćazim Ćatić"	Zenica	10,1	5,1	2825	-	ZDK	107	1238	DA	Sjever	1953	2	67	-	2014	Ceteor	*	-	Po+P+1
115	ZDK-ZEN-02	OŠ "Mak Dizdar"	Zenica	10,1	5,1	2825	-	ZDK	70	812	DA	Sjever	1961	2	59	-	2015	Zagreb inspekt	*	-	P+3
116	ZDK-ZEN-03	OŠ "Aleksa Šantić" Perin Han	Zenica	10,1	5,1	2825	-	ZDK	43	344	DA	Sjever	1936	1	84	-	2016	Ceteor	*	-	Po+P+1
117	ZDK-ZEN-04	OŠ "Arnauti"	Zenica	10,1	5,1	2825	-	ZDK	44	316	DA	Sjever	1949	2	71	-	2016	Ceteor	*	-	P+1
118	ZDK-ZEN-05	Druga gimnazija i Ekonomska škola	Zenica	10,1	5,1	2825	-	ZDK	98	799	DA	Sjever	1970	3	50	-	2018	Zagreb inspekt	*	-	Po+P+2
119	ZDK-ZEN-06	PŠ "Blatuša"	Zenica	10,1	5,1	2825	-	ZDK	30	307	DA	Sjever	1957	2	63	-	2018	Euroing	*	-	P+2
120	ZDK-KAK-01	OŠ "Rešad Kadić"	Kakanj	10,1	5,1	2825	-	ZDK	43	197	DA	Sjever	1968	3	52	-	2016	Ceteor	*	-	P+1
121	ZDK-KAK-02	OŠ "15 April"	Kakanj	10,1	5,1	2825	-	ZDK	68	667	DA	Sjever	1914	1	106	-	2015	Zagreb inspekt	*	-	P+1
122	ZDK-KAK-03	OŠ "Hamdija Kreševljaković"	Kakanj	10,1	5,1	2825	-	ZDK	85	995	DA	Sjever	1960	2	60	-	2015	Zagreb inspekt	*	-	P+2
123	ZDK-KAK-04	Srednja škola Gimnazija Muhsin Rizvić	Kakanj	10,1	5,1	2825	-	ZDK	46	350	DA	Sjever	1984	4	36	-	2017	Zagreb inspekt	*	-	P+2
124	ZDK-VAR-01	OŠ "Vareš"	Vareš	10,1	5,1	2825	-	ZDK	60	320	DA	Sjever	1951	2	69	-	2016	Ceteor	*	-	P+2
125	ZDK-BRE-01	OŠ "Enver Čolaković"	Breza	10,1	5,1	2825	BA-71370-0005-1	ZDK	55	548	DA	Sjever	1962	2	58	1997	2015	Zagreb inspekt	2018	-	Po+P+2
126	ZDK-BRE-02	OŠ "Safvet-beg Bašagić"	Breza	10,1	5,1	2825	-	ZDK	70	465	DA	Sjever	1977	4	43	-	2017	Zagreb inspekt	*	-	Po+P+2
127	ZDK-VIS-01	OŠ "Safvet-beg Bašagić"	Visoko	10,1	5,1	2825	-	ZDK	79	993	DA	Sjever	1965	2	55	-	2015	Zagreb inspekt	*	-	P+1
128	ZDK-VIS-02	OŠ "Alija Nametak Buci"	Visoko	10,1	5,1	2825	-	ZDK	49	436	DA	Sjever	1978	4	42	-	2017	Zagreb inspekt	*	-	P+1
129	ZDK-VIS-03	OŠ "Kulin Ban"	Visoko	10,1	5,1	2825	-	ZDK	50	370	DA	Sjever	1909	1	111	-	2014	Enova	*	-	Po+P+2
130	ZDK-OLO-01	OŠ "Hasan Kikić"	Olovo	10,1	5,1	2825	BA-71340-0004-1	ZDK	30	180	DA	Sjever	1964	2	56	1997	2014	Ceteor	2015	-	P+1
131	ZHK-POS-01	OŠ "Ante Brune Bušića" Rakitno	Posušje	10,6	5,5	2627	BA-88240-0002-1	ZHK	32	250	DA	Sjever	1959	2	61	-	2014	Zagreb inspekt	2015	-	P+1
132	ZHK-POS-02	OŠ "Franice Dall"era" Vir	Posušje	10,6	5,5	2627	BA-88240-0003-1	ZHK	10	110	DA	Sjever	1978	4	42	2012	2016	CRP Tuzla	2016	-	P+2
133	ZHK-POS-03	OŠ "Ivana Mažuranića"	Posušje	10,6	5,5	2627	BA-88240-0001-1	ZHK	133	1300	DA	Sjever	1979	4	41	2014	2016	Zagreb inspekt	2016	-	Po+P+2
134	ZHK-POS-04	Srednja škola Posušje, Osnovna glazbena škola	Posušje	10,6	5,5	2627	-	ZHK	123	1501	DA	Sjever	1951	2	69	1995	2016	CRP Tuzla	*	-	P+2
135	ZHK-POS-05	OŠ "Vranić"	Posušje	10,6	5,5	2627	-	ZHK	30	91	NE	Jug	1968	3	52	2018	2018	Zagreb inspekt	*	-	P+1
136	ZHK-SB-01	OŠ "Kočerin"	Široki Brijeg	12,8	5,8	1907	BA-88220-0003-1	ZHK	45	310	NE	Jug	1968	3	52	-	2014	Zagreb inspekt	2016	-	Po+P+1
137	ZHK-SB-02	"Prva osnovna škola"	Široki Brijeg	12,8	5,8	1907	BA-88220-0001-1	ZHK	60	700	DA	Jug	1975	4	45	-	2013	Ceteor	2016	2524,0	P+2
138	ZHK-SB-03	OŠ "Biograci"	Široki Brijeg	12,8	5,8	1907	BA-88220-0006-1	ZHK	20	220	DA	Jug	1973	3	47	2006	2016	CRP Tuzla	2017	-	Po+P+2
139	ZHK-SB-04	Prva osnovna škola - PŠ "Mala škola"	Široki Brijeg	12,8	5,8	1907	BA-88220-0001-2	ZHK	20	250	NE	Jug	1954	2	66	-	2014	Građ. fak. Mostar	2016	-	P+1
140	ZHK-SB-05	Druga OŠ Široki Brijeg, PŠ DONJI CRNAČ	Široki Brijeg	12,8	5,8	1907	-	ZHK	3	27	NE	Jug	1948	2	72	-	2016	Ceteor/Zagreb inspekt	2019	-	P
141	ZHK-LJUB-01	OŠ "Ivana Brlić Mažuranić"	Ljubuški	12,8	5,8	1907	BA-88320-0003-1	ZHK	80	900	DA	Jug	1983	4	37	-	2015	Zagreb inspekt	2015	-	P+1
142	ZHK-LJUB-02	OŠ "Tina Ujevića" - PŠ "Grab"	Ljubuški	12,8	5,8	1907	BA-88320-0001-6	ZHK	20	220	NE	Jug	1913	1	107	-	2016	CRP Tuzla	2016	-	Po+P+1
143	ZHK-LJUB-03	OŠ "Marka Marulića", PŠ Miletina	Ljubuški	12,8	5,8	1907	-	ZHK	5	30	NE	Jug	1948	2	72	1998	2016	Zagreb inspekt	*	-	P+1
144	ZHK-GRU-01	OŠ "Ruđer Bošković"	Grude	12,8	5,8	1907	BA-88340-0006-1	ZHK	80	900	DA	Jug	1983	4	37	2004	2015	Zagreb inspekt	2015	-	P+1
145	ZHK-GRU-02	OŠ "Fra Stipana Vrljića" Sovići	Grude	12,8	5,8	1907	BA-88340-0007-1	ZHK	35	230	DA	Jug	1976	4	44	2010	2016	Zagreb inspekt	2017	-	P+2
146	ZHK-GRU-03	OŠ Antuna Branka i Stanislava Šimića Drinovci	Grude	12,8	5,8	1907	BA-88340-0008-1	ZHK	38	320	DA	Jug	1963	2	57	2014	2016	CRP Tuzla	2017	-	Po+P+2
147	ZHK-GRU-04	OŠ "Antuna Branka i Stanislava Šimića" - PŠ "T	Grude	12,8	5,8	1907	BA-88340-0008-2	ZHK	10	132	DA	Jug	1977	4	43	2014	2016	CRP Tuzla	2016	-	Po+P+1
148	ZHK-GRU-05	Srednja škola Antuna Branka Šimića	Grude	12,8	5,8	1907	-	ZHK	50	820	DA	Jug	1964	2	56	2001	2016	Zagreb inspekt	*	-	Po+P+1
149	HNK-CIT-01	'OŠ Čerin''	Čitluk	12,8	5,8	1907	-	HNŽ	50	284	DA	Jug	1974	4	46	-	2018	Zagreb inspekt	*		P+1
150	HNK-CIT-02	'OŠ Fra Didaka Buntića'' Čitluk	Čitluk	12,8	5,8	1907	-	HNŽ	70	940	DA	Jug	1966	3	54	-	2014	Građ. fak. Mostar	*	-	P+1
151	HNK-RAM-01	OŠ "Ripci" Prozor Rama	Prozor - Rama	10,6	5,2	2729	-	HNŽ	35	250	DA	Jug	1968	3	52	-	2016	Građ. fak. Mostar	*	-	Po+P+2
152	HNK-RAM-02	SŠ "Prozor Rama''	Prozor - Rama	10,6	5,2	2729	-	HNŽ	48	386	DA	Jug	1981	4	39	-	2016	Zagreb inspekt	*	-	P+1
153	HNK-RAM-03	OŠ "Gračac"	Prozor - Rama	10,6	5,2	2729	-	HNŽ	28	60	DA	Jug	1976	4	44	-	2018	Zagreb inspekt	*	-	P+1
154	HNK-KONJ-01	OŠ "Čelebići"	Konjic	14,6	7,5	1689	BA-88400-0007-1	HNŽ	30	190	DA	Jug	1960	2	60	1981	2017	Ceteor	2018	-	P+2
155	HNK-JAB-01	OŠ "Suljo Čilić"	Jablanica	14,6	7,5	1689	BA-88420-0012-1	HNŽ	84	529	DA	Jug	1974	4	46	1998	2015	Ceteor	2018	5673,6	Po+P+2
156	HNK-MOS-01	OŠ "Bijelo polje", Potoci	Mostar	14,6	7,5	1689	BA-88000-0044-1	HNŽ	58	472	DA	Jug	1972	3	48	1995	2017	Ceteor	2018	3424,2	P+2
157	HNK-MOS-02	OŠ "Ilići" Mostar	Mostar	14,6	7,5	1689	BA-88000-0033-1	HNŽ	27	189	DA	Jug	1966	3	54	-	2017	Ceteor	2018	1272,8	P
158	HNK-MOS-03	'III osnovna škola'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	42	295	NE	Jug	1970	3	50	-	2017	Ceteor	*		P+2
159	HNK-MOS-04	'IV osnovna škola'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	78	526	DA	Jug	1975	4	45	-	2016	Zagreb inspekt	*		P+3
160	HNK-MOS-05	'V osnovna škola'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	59	656	DA	Jug	1977	4	43	-	2017	Ceteor	2019		P+1
161	HNK-MOS-06	'VI osnovna škola'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	66	538	DA	Jug	1956	2	64	1995	2017	Ceteor	*		Po+P+2
162	HNK-MOS-07	'VIII osnovna škola'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	52	463	NE	Jug	1979	4	41	1995	2017	Ceteor	*		Po+P+2

R. br.	Šifra-rad	Naziv/grad/županija: Naziv škole	Grad	Srednja godišnja temp.	Srednja mjesečna temperatura u sezoni grijanja	Broj stupanj dana u sezoni grijanja	ISSE - šifra	Županija	Broj uposlenih/korisnika: Broj uposlenih	Broj učenika
163	HNK-MOS-08	'X osnovna škola'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	54	665
164	HNK-MOS-09	OŠ ''Ilija Jakovljević'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	46	523
165	HNK-MOS-10	OŠ ''Zalik'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	55	417
166	HNK-MOS-11	OŠ ''Mustafa Ejubović – Šejh Jujo'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	73	730
167	HNK-MOS-12	Srednja građevinska šk. Juraj Dalmatinac	Mostar	14,6	7,5	1689	-	HNŽ	85	498
168	HNK-MOS-13	Srednja prometna škola	Mostar	14,6	7,5	1689	-	HNŽ	120	700
169	HNK-MOS-14	'OŠ Gnojnice'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	36	360
170	HNK-MOS-15	OŠ "Cim" Mostar	Mostar	14,6	7,5	1689	-	HNŽ	28	188
171	HNK-MOS-16	OŠ "Omer Maksumić" Podvelež	Mostar	14,6	7,5	1689	-	HNŽ	21	32
172	HNK-MOS-17	'OŠ za djecu sa posebnim potrebama'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	26	57
173	HNK-MOS-18	'OŠ Vrapčići'' Mostar	Mostar	14,6	7,5	1689	-	HNŽ	36	288
174	HNK-MOS-19	'OŠ Marina Držića'' Buna	Mostar	14,6	7,5	1689	-	HNŽ	45	380
175	HNK-MOS-20	'OŠ Bartola Kašića'' Rodoč	Mostar	14,6	7,5	1689	-	HNŽ	40	330
176	HNK-MOS-21	'OŠ Blagaj''	Mostar	14,6	7,5	1689	-	HNŽ	40	300
177	HNK-MOS-22	'OŠ Drežnica''	Mostar	14,6	7,5	1689	-	HNŽ	30	74
178	HNK-MOS-23	'OŠ Kruševo''	Mostar	14,6	7,5	1689	-	HNŽ	30	130
179	HNK-STO-01	'OŠ Stolac''	Stolac	14,6	7,5	1689	-	HNŽ	79	659
180	HNK-STO-02	'OŠ Crnići''	Stolac	14,6	7,5	1689	-	HNŽ	47	282
181	HNK-CAP-01	OŠ "Lipanjske zore" - PŠ "Domanovići"	Čapljina	14,6	7,5	1689	BA-88300-0009-4	HNŽ	26	174
182	HNK-CAP-02	PŠ "Svitava''	Čapljina	14,6	7,5	1689	-	HNŽ	5	12
183	HNK-RAV-01	OŠ "Ravno''	Ravno	14,6	7,5	1689	-	HNŽ	6	10
184	HNK-RAV-02	PŠ "Ivanica''	Ravno	14,6	7,5	1689	-	HNŽ	4	8
185	HNK-NEU-01	'OŠ Neum''	Neum	14,6	7,5	1689	-	HNŽ	40	340

R. br.	Opći podatci o zgradi: Škola sa dvoranom (DA/NE)	Regija (Sjever/Jug)	Godina izgradnje	Razdoblje izgradnje prema tipologiji javnih zgrada	Starost zgrade u odnosu na 2020. godinu	Godina značajne rekonstrukcije i obnove	Godina izrade DEA	Izrađivač DEA	Godina energetske obnove	Geometrijski podatci o zgradi: Tlocrtna bruto površina	Broj etaža	Neto površina (m2)	Korisna površina Ak (m2)	Površina ovojnice grijanog dijela zgrade A (m2)	Volumen grijanog dijela zgrade Ve (m3)	Volumen grijanog zraka V (m3)	Faktor oblika f=A/Ak	Faktor kompaktnosti fo=A/Ve
163	DA	Jug	1962	2	58	-	2017	Ceteor	*		Po+P+2	-	2819,2	4781,7	11697,6	8890,2	1,70	0,41
164	NE	Jug	2002	5	18	-	2017	Ceteor	*		P+1	-	1866,9	3851,1	6400,8	4864,6	2,06	0,60
165	DA	Jug	2014	6	6	-	2017	Ceteor	*		Po+P+2	-	4029,7	8463,5	21382,5	16250,7	2,10	0,40
166	DA	Jug	1986	4	34	-	2017	Ceteor	*		Po+P+2	-	3389,4	6455,1	14900,1	11324,0	1,90	0,43
167	DA	Jug	1960	2	60	-	2015	Zagreb inspekt	*		Po+P+1	-	1800,0	4606,0	6200,0	4712,0	2,56	0,74
168	NE	Jug	1896	1	124	2006	2016	Zagreb inspekt	*		Po+P+2	-	2465,0	4809,0	10460,0	7949,6	1,95	0,46
169	NE	Jug	1971	3	49	-	2017	Ceteor	*		P+1	-	493,6	1621,0	1767,6	1482,4	3,28	0,92
170	NE	Jug	1973	3	47	-	2017	Ceteor	*		P	-	608,3	1781,9	1923,6	1538,9	2,93	0,93
171	DA	Jug	2000	5	20	-	2017	Ceteor	*		P+1	-	1200,1	2814,3	7078,4	5379,6	2,35	0,40
172	NE	Jug	2001	5	19	-	2017	Ceteor	*		P+1	-	358,3	918,3	1092,8	830,5	2,56	0,84
173	DA	Jug	1978	4	42	1995	2017	Ceteor	*		P	-	1396,0	4345,5	7302,2	5549,7	3,11	0,60
174	DA	Jug	1980	4	40	-	2017	Ceteor	*		P+1	-	2465,0	4880,1	8215,4	6243,7	1,98	0,59
175	NE	Jug	1962	2	58	-	2017	Ceteor	*		P+1	-	1863,4	4030,3	7985,8	6149,1	2,16	0,50
176	DA	Jug	1974	4	46	-	2017	Ceteor	*		P+1	-	1470,6	4862,0	5073,0	3855,5	3,31	0,96
177	DA	Jug	1980	4	40	1995	2017	Ceteor	*		P+1	-	1767,8	4097,6	7732,1	5876,4	2,32	0,53
178	NE	Jug	1940	1	80	-	2017	Ceteor	*		Po+P+1	-	1258,6	2597,8	4426,7	3359,7	2,06	0,59
179	NE	Jug	1952	2	68	-	2016	Građ. fak. Mostar	*		Po+P+2	-	2920,7	5341,2	14069,6	10222,5	1,83	0,38
180	NE	Jug	1957	2	63	-	2014	Građ. fak. Mostar	*		P+1	-	1085,4	2361,4	4697,0	3669,0	2,18	0,50
181	DA	Jug	1963	2	57	-	2015	Građ. fak. Mostar	2016/18	-	Po+P+1	-	1023,5	2425,5	4508,0	3472,0	2,37	0,54
182	NE	Jug	1981	4	39	-	2017	Građ. fak. Mostar	*	-	P	-	83,6	327,9	325,3	250,8	3,92	1,01
183	NE	Jug	1910	1	110	1999	2014	Građ. fak. Mostar	*	-	P+1	-	572,5	1364,4	2765,0	2147,9	2,38	0,49
184	NE	Jug	2001	5	19	-	2018	Građ. fak. Mostar	*	-	P+1	-	395,3	1180,8	1877,2	1508,6	2,99	0,63
185	NE	Jug	1983	4	37	-	2016	Građ. fak. Mostar	*		Po+P+1	-	1484,0	2528,0	5344,3	4394,6	1,70	0,47

R. br.	Podatci o energentu za grijanje: Energent za grijanje	Oznaka energenta	Jedinica mjere energenta	Režim rada sustava grijanja (dnevno sati)	Podatci o stvarnoj potrošnji i troškovima isporučene toplinske energije za grijanje (QH,del): Godišnja isporučena toplinska energija za grijanje - QH,del (KWh/god)	Godišnja specifična potrošnja isporučene energije za grijanje - QH',del (KWh/m2 god)	Godišnja količina energenata za grijanje	Godišnji trošak isporučene toplinske energije za grijanje - CQH,del (KM/god)	Jedinični trošak energenata za grijanje - UCQH,del (KM/kWh)	Specifični godišnji trošak isporučene toplinske energije za grijanje - C'QH,del (KM/m2god)	Podatci o stvarnoj potrošnji i troškovima isporučene električne energije (E,del): Godišnja potrošnja isporučene električne energije - E,del (KWh/god)	Godišnja specifična potrošnja isporučene električne energije - E',del (KWh/m2god)	Godišnji trošak isporučene električne energije - CE,del (KM/god)	Jedinični trošak električne energije - UCE,del (KM/kWh)	Godišnji specifični trošak isporučene električne energije - C'E,del (KM/m2god)
163	ELLU	3	l	10	229335	81,35	22865	32040	0,140	11,36	23976	8,50	6171	0,257	2,19
164	ELLU	3	l	11	91425	48,97	9115	14075	0,154	7,54	27724	14,85	7936	0,286	4,25
165	Pelet	2	t	11	65000	16,13	13	4000	0,062	0,99	32898	8,16	8596	0,261	2,13
166	ELLU	3	l	11	158120	46,65	15765	25265	0,160	7,45	22895	6,75	5849	0,255	1,73
167	ELLU	3	l	8	193880	107,71	19330	39630	0,204	22,02	37361	20,76	8947	0,239	4,97
168	ELLU	3	l	9	351050	142,41	35000	70000	0,199	28,40	51537	20,91	13179	0,256	5,35
169	ELLU	3	l	11	106465	215,69	10615	17315	0,163	35,08	5940	12,03	1534	0,258	3,11
170	Drvo	1	m3	12	180770	297,17	98,00	7850	0,043	12,90	8718	14,33	1937	0,222	3,18
171	LU	3	l	6	83750	69,79	8350	13720	0,164	11,43	3515	2,93	954	0,271	0,79
172	El. energ.	6	kWh	8	29190	81,47		7093	0,243	19,80	10795	30,13	2623	0,243	7,32
173	ELLU	3	l	9	84252	60,35	8400	13440	0,160	9,63	14479	10,37	3357	0,232	2,40
174	ELLU	3	l	9	147460	59,82	14700	25122	0,170	10,19	20060	8,14	5588	0,279	2,27
175	Drvo	1	m3	10	183600	98,53	102,00	9550	0,052	5,13	27630	14,83	7405	0,268	3,97
176	ELLU	3	l	11	96500	65,62	11915	17080	0,177	11,61	9657	6,57	2539	0,263	1,73
177	Drvo	1	m3	9	223200	126,26	124,0	11070	0,050	6,26	20682	11,70	5295	0,256	3,00
178	ELLU	3	l	8	75827	60,25	7560	12810	0,169	10,18	7182	5,71	2208	0,307	1,75
179	ELLU	3	l	10	103760	35,53	10345	16895	0,163	5,78	23498	8,05	6108	0,260	2,09
180	Drvo	1	m3	10	106200	97,84	59	5450	0,051	5,02	9165	8,44	2525	0,276	2,33
181	Drvo	1	m3	10	145260	141,92	80,7	7260	0,050	7,09	10750	10,50	2980	0,277	2,91
182	Drvo	1	m3	6	30600	366,03	17	1530	0,050	18,30	2765	33,07	951	0,344	11,38
183	ELLU	3	l	6	40120	70,08	4000	8700	0,217	15,20	8052	14,06	2818	0,350	4,92
184	El. energ.	6	kWh	8	5400	13,66	1800	533	0,099	1,35	540	1,37	160	0,296	0,40
185	ELLU	3	l	11	96960	65,34	9667	15783	0,163	10,64	18286	12,32	4750	0,260	3,20

R. br.	Podatci o karakteristikama ovojnice zgrade: Površina zida Z1 (m2)	U koef. (W/m2K) zida Z1	Ht=P*U (W/2K) zida Z1	Površina zida Z2 (m2)	U koef. (W/m2K) zida Z2	Ht=P*U (W/2K) zida Z2	Površina zida Z3 (m2)	U koef. (W/m2K) zida Z3	Ht=P*U (W/2K) zida Z3	Površina zida Z4 (m2)	U koef. (W/m2K) zida Z4	Ht=P*U (W/2K) zida Z4	Ukupna površina zidova (m2)	Prosječni U koef. (W/m2K) za zidove
163	1094,9	1,95	2135,1	251,8	3,32	836,0	45,2	0,79	35,7	23,1	1,01	23,3	1415,0	2,14
164	766,5	0,27	207,0	136,1	0,27	36,7	270,4	0,20	54,1	0,0	0,00	0,0	1173,0	0,25
165	1049,8	0,32	335,9	233,0	0,43	100,2	811,3	0,25	202,8	141,4	0,75	106,1	2235,5	0,33
166	1190,4	3,82	4547,3	916,6	1,15	1054,1	222,9	2,62	584,0	19,8	2,30	45,5	2349,7	2,65
167	962,0	1,35	1298,7	437,0	1,35	590,0	0,0	0,00	0,0	0,0	0,00	0,0	1399,0	1,35
168	2420,0	1,67	4041,4	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	2420,0	1,67
169	343,6	1,93	663,1	53,7	1,49	80,0	270,2	1,42	383,7	56,4	2,30	129,7	723,9	1,74
170	227,8	1,93	439,7	100,2	1,93	193,4	0,0	0,00	0,0	0,0	0,00	0,0	328,0	1,93
171	430,6	0,42	180,9	281,9	0,36	101,5	6,0	3,61	21,7	0,0	0,00	0,0	718,5	0,42
172	396,1	2,04	808,0	61,4	1,77	108,7	0,0	0,00	0,0	0,0	0,00	0,0	457,5	2,00
173	207,7	3,13	650,1	58,6	2,52	147,7	748,1	1,33	995,0	0,0	0,00	0,0	1014,4	1,77
174	680,2	1,41	959,1	146,8	3,53	518,2	57,5	3,22	185,2	82,4	2,33	192,0	966,9	1,92
175	310,7	1,32	410,1	629,1	1,64	1031,7	160,0	3,29	526,4	0,0	0,00	0,0	1099,8	1,79
176	1220,0	1,44	1756,8	365,0	1,44	525,6	40,0	1,34	53,6	0,0	0,00	0,0	1625,0	1,44
177	619,7	1,83	1134,1	350,8	3,18	1115,5	63,6	2,78	176,8	0,0	0,00	0,0	1034,1	2,35
178	809,4	1,6	1295,0	34,7	1,67	57,9	65,0	1,68	109,2	96,2	0,77	74,1	1005,3	1,53
179	905,9	1,75	1585,3	550,6	1,42	781,9	586,3	1,73	1014,3	85,3	2,00	170,6	2128,1	1,67
180	479,4	1,62	776,6	271,9	1,28	348,0	0,0	0,00	0,0	0,0	0,00	0,0	751,3	1,50
181	606,4	1,48	897,5	49,7	3,00	149,1	16,4	1,89	31,0	0,0	0,00	0,0	672,5	1,60
182	105,7	1,45	153,3	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	105,7	1,45
183	559,0	1,62	905,6	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	559,0	1,62
184	299,5	1,35	404,3	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	299,5	1,35
185	436,7	3,37	1471,7	227,0	1,35	306,5	20,6	4,31	88,8	0,0	0,00	0,0	684,3	2,73

R. br.	Površina poda P1 (m2)	U koef. (W/m2K) poda P1	Ht=P*U (W/2K) poda P1	Površina poda P2 (m2)	U koef. (W/m2K) poda P2	Ht=P*U (W/2K) poda P2	Površina poda P3 (m2)	U koef.U (W/m2K) poda P3	Ht=P*U (W/2K) poda P3	Ukupna površina podova (m2)	Prosječni U koef. (W/m2K) za podove
163	1140,8	2,81	3205,6	101,3	2,65	268,4	0,0	0,00	0,0	1242,1	2,80
164	1041,0	0,34	353,9	0,0	0,00	0,0	0,0	0,00	0,0	1041,0	0,34
165	1437,1	0,8	1149,7	1095,2	0,40	438,1	26,8	0,46	12,3	2559,1	0,63
166	1032,9	1,95	2014,2	242,7	0,59	143,2	85,4	2,05	175,1	1361,0	1,71
167	600,0	1,93	1158,0	600,0	1,40	840,0	0,0	0,00	0,0	1200,0	1,67
168	970,0	1,07	1037,9	0,0	0,00	0,0	0,0	0,00	0,0	970,0	1,07
169	196,3	3,8	745,9	146,9	3,80	558,2	0,0	0,00	0,0	343,2	3,80
170	608,3	1,65	1003,7	0,0	0,00	0,0	0,0	0,00	0,0	608,3	1,65
171	800,5	0,39	312,2	0,0	0,00	0,0	0,0	0,00	0,0	800,5	0,39
172	177,8	0,9	160,0	0,0	0,00	0,0	0,0	0,00	0,0	177,8	0,90
173	731,8	1,98	1449,0	87,0	1,98	172,3	577,2	1,60	923,5	1396,0	1,82
174	1212,4	2,81	3406,8	287,0	1,83	525,2	0,0	0,00	0,0	1499,4	2,62
175	1148,1	3,62	4156,1	0,0	0,00	0,0	0,0	0,00	0,0	1148,1	3,62
176	935,0	4,1	3833,5	197,0	4,10	807,7	0,0	0,00	0,0	1132,0	4,10
177	984,0	2,73	2686,3	292,8	2,07	606,1	0,0	0,00	0,0	1276,8	2,58
178	246,5	1,99	490,5	278,8	1,18	329,0	115,3	2,06	237,5	640,6	1,65
179	645,1	1,84	1187,0	367,6	1,84	676,4	0,0	0,00	0,0	1012,7	1,84
180	673,9	1,73	1165,8	0,0	0,00	0,0	0,0	0,00	0,0	673,9	1,73
181	123,2	4,1	505,1	367,2	3,94	1446,8	233,6	3,94	920,4	724,0	3,97
182	100,1	3,75	375,4	0,0	0,00	0,0	0,0	0,00	0,0	100,1	3,75
183	350,0	1,75	612,5	0,0	0,00	0,0	0,0	0,00	0,0	350,0	1,75
184	385,9	3,83	1478,0	0,0	0,00	0,0	0,0	0,00	0,0	385,9	3,83
185	731,0	3,62	2646,2	0,0	0,00	0,0	0,0	0,00	0,0	731,0	3,62

R. br.	Površina stropa S1 (m2)	U koef. (W/m2K) stropa S1	Ht=P*U (W/2K) stropa S1	Površina stropa S2 (m2)	U koef. (W/m2K) stropa S2	Ht=P*U (W/2K) stropa S2	Površina stropa S3 (m2)	U koef. (W/m2K) stropa S3	Ht=P*U (W/2K) stropa S3	Površina stropa S4 (m2)	U koef. (W/m2K) stropa S4	Ht=P*U (W/2K) stropa S4	Ukupna površina stropva (m2)	Prosječni U koef. (W/m2K) za stropove
163	760,8	2,64	2008,5	280,4	3,79	1062,7	211,8	2,94	622,7	66,7	3,03	202,1	1319,7	2,95
164	921,7	0,30	276,5	78,0	0,32	25,0	29,5	2,50	73,8	121,7	0,29	35,3	1150,9	0,36
165	1697,3	0,27	458,3	1140,8	0,35	399,3	199,7	0,87	173,7	0,0	0,00	0,0	3037,8	0,34
166	972,8	2,88	2801,7	748,0	0,41	306,7	177,4	0,65	115,3	23,6	2,93	69,1	1921,8	1,71
167	1200,0	3,14	3768,0	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	1200,0	3,14
168	510,0	0,38	193,8	460,0	2,24	1030,4	0,0	0,00	0,0	0,0	0,00	0,0	970,0	1,26
169	213,7	3,69	788,6	149,8	1,69	253,2	32,6	2,24	73,0	16,0	4,00	64,0	412,1	2,86
170	473,2	1,93	913,3	225,1	2,68	603,3	0,0	0,00	0,0	0,0	0,00	0,0	698,3	2,17
171	536,8	0,40	214,7	189,4	0,56	106,1	222,0	0,55	122,1	0,0	0,00	0,0	948,2	0,47
172	202,5	0,57	115,4	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	202,5	0,57
173	546,1	3,69	2015,1	706,2	0,19	134,2	254,4	2,28	580,0	109,4	2,28	249,4	1616,1	1,84
174	1477,0	0,51	753,3	321,0	0,50	160,5	0,0	0,00	0,0	18,4	2,15	39,6	1816,4	0,52
175	380,0	4,27	1622,6	930,0	3,69	3431,7	0,0	0,00	0,0	0,0	0,00	0,0	1310,0	3,86
176	770,0	1,47	1131,9	240,0	1,47	352,8	411,0	1,41	579,5	0,0	0,00	0,0	1421,0	1,45
177	703,8	3,60	2533,7	393,0	0,64	251,5	150,0	0,60	90,0	0,0	0,00	0,0	1246,8	2,31
178	206,1	1,36	280,3	40,4	2,83	114,3	472,4	1,89	892,8	0,0	0,00	0,0	718,9	1,79
179	845,3	1,19	1005,9	367,6	3,37	1238,8	200,3	2,53	506,8	0,0	0,00	0,0	1413,2	1,95
180	673,9	3,60	2426,0	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	673,9	3,60
181	491,1	1,77	869,2	198,4	1,79	355,1	34,5	2,10	72,5	3,0	3,11	9,3	727,0	1,80
182	100,1	3,60	360,4	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	100,1	3,60
183	350,0	2,29	801,5	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	350,0	2,29
184	283,5	1,04	294,8	124,7	1,04	129,7	0,0	0,00	0,0	0,0	0,00	0,0	408,2	1,04
185	735,6	2,29	1684,5	72,0	2,70	194,4	0,0	0,00	0,0	0,0	0,00	0,0	807,6	2,33

R. br.	Površina otvora O1 (m2)	U koef. (W/m2K) otvora O1	Ht=P*U (W/2K) otvora O1	Površina otvora O2 (m2)	U koef. (W/m2K) otvora O2	Ht=P*U (W/2K) otvora O2	Površina otvora O3 (m2)	U koef. (W/m2K) otvora O3	Ht=P*U (W/2K) otvora O3	Površina otvora O4 (m2)	U koef. (W/m2K) otvora O4	Ht=P*U (W/2K) otvora O4	Ukupna površina otvora (m2)	Prosječni U koef. (W/m2K) za otvore	Prosječna U - vrijednost ovojnice (W/m2K)
163	646,3	2,20	1421,9	70,6	2,90	204,7	40,1	2,50	100,3	47,9	5,90	282,6	804,9	2,50	2,60
164	480,6	2,20	1057,3	5,6	2,20	12,3	0,0	0,00	0,0	0,0	0,00	0,0	486,2	2,20	0,55
165	447,8	1,40	626,9	183,3	1,60	293,3	0,0	0,00	0,0	0,0	0,00	0,0	631,1	1,46	0,51
166	457,3	2,20	1006,1	8,1	2,50	20,3	21,6	5,90	127,4	335,6	3,80	1275,3	822,6	2,95	2,21
167	114,0	1,80	205,2	140,0	3,50	490,0	475,0	3,50	1662,5	78,0	5,00	390,0	807,0	3,40	2,26
168	370,0	3,60	1332,0	16,0	3,60	57,6	63,0	5,90	371,7	0,0	0,00	0,0	449,0	3,92	1,68
169	32,3	2,90	93,7	98,0	2,90	284,2	11,5	5,90	67,9	0,0	0,00	0,0	141,8	3,14	2,58
170	134,6	3,00	403,8	10,0	5,90	59,0	0,0	0,00	0,0	2,7	5,90	15,9	147,3	3,25	2,04
171	181,7	1,80	327,1	22,5	2,90	65,3	140,2	5,90	827,2	0,0	0,00	0,0	344,4	3,54	0,81
172	80,5	1,80	144,9	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	80,5	1,80	1,46
173	313,7	2,00	627,4	5,3	5,90	31,3	0,0	0,00	0,0	0,0	0,00	0,0	319,0	2,06	1,84
174	262,1	2,20	576,6	90,8	3,80	345,0	61,8	5,90	364,6	182,7	3,80	694,3	597,4	3,32	1,79
175	307,0	1,80	552,6	102,2	3,60	367,9	63,2	5,90	372,9	0,0	0,00	0,0	472,4	2,74	3,09
176	268,2	1,80	482,8	316,8	3,60	1140,5	99,0	5,90	584,1	0,0	0,00	0,0	684,0	3,23	2,31
177	166,4	1,80	299,5	271,9	2,90	788,5	48,8	5,90	287,9	52,8	3,80	200,6	539,9	2,92	2,48
178	117,4	2,20	258,3	101,7	2,90	294,9	8,6	5,90	50,7	5,3	3,80	20,1	233,0	2,68	1,73
179	739,7	3,00	2219,1	47,5	5,00	237,5	0,0	0,00	0,0	0,0	0,00	0,0	787,2	3,12	1,99
180	262,3	3,60	944,3	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	262,3	3,60	2,40
181	250,6	3,60	902,2	51,4	5,00	257,0	0,0	0,00	0,0	0,0	0,00	0,0	302,0	3,84	2,64
182	22,0	2,90	63,8	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	22,0	2,90	2,91
183	88,2	2,90	255,8	17,2	3,30	56,8	0,0	0,00	0,0	0,0	0,00	0,0	105,4	2,97	1,93
184	87,2	3,00	261,6	0,0	0,00	0,0	0,0	0,00	0,0	0,0	0,00	0,0	87,2	3,00	2,18
185	290,5	3,80	1103,9	14,6	2,80	40,9	0,0	0,00	0,0	0,0	0,00	0,0	305,1	3,75	2,98

R. br.	Hd - koef. transmisijske izmjene topline prema vanjskom okolišu (W/K)	Hg - koef. transmisijske izmjene topline prema tlu (W/K)	Hu/Ha - koef. transmisijske izmjene kroz negrijani prostor ili susjednim zgradama (W/K)	Ukupna površina građevinskih dijelova ovojnice A (m2)	Ukupan koeficijent transmisijske izmjene topline Htr (W/K)	Koeficijent transmisijske izmjene topline po korisnoj površini Ak Ht'' (W/m2K)	Koeficijent transmisijske izmjene topline po površini ovojnice Ht' (W/m2K)	Dopuštena vrijednost koef. trans. izmjene topline H'tr,dop (W/m2K)	Usporedba stvarne i dopuštene vrijednost koef. trans. izmjene topline	Ukupan koeficijent ventilacijske izmjene topline Hve (W/K)	Ukupan koeficijent toplinskog gubitka (izmjene topline): Ukupan koeficijent toplinskog gubitka: H=Ht+Hve (W/K)	Ukupan koeficijent toplinskog gubitka po površini ovojnice H' (W/m2K)
163	9209,0	721,7	0,0	4781,7	9930,7	3,52	2,08	1,04	2,00	3574,0	13504,7	2,82
164	1894,1	322,2	0,0	3851,1	2216,3	1,19	0,58	0,70	0,82	2770,0	4986,3	1,29
165	2960,2	641,6	123,0	8463,5	3724,8	0,92	0,44	0,83	0,53	5444,0	9168,8	1,08
166	12379,9	848,8	144,2	6455,1	13372,9	3,95	2,07	0,80	2,59	5690,0	19062,9	2,95
167	8664,3	606,1	0,0	4606,0	9270,4	5,15	2,01	0,77	2,61	3157,0	12427,4	2,70
168	7365,9	444,8	0,0	4809,0	7810,7	3,17	1,62	0,78	2,08	5326,0	13136,7	2,73
169	2994,6	330,7	157,0	1621,0	3482,3	7,05	2,15	0,61	3,52	745,0	4227,3	2,61
170	2730,9	252,4	0,0	1781,9	2983,3	4,90	1,67	0,71	2,36	1289,0	4272,3	2,40
171	2133,0	393,6	0,0	2811,6	2526,6	2,11	0,90	1,05	0,86	2703,0	5229,6	1,86
172	1243,0	485,7	0,0	918,3	1728,7	4,82	1,88	0,63	2,99	473,0	2201,7	2,40
173	5693,2	1060,5	51,5	4345,5	6805,2	4,87	1,57	0,70	2,24	2231,0	9036,2	2,08
174	5066,6	1195,8	0,0	4880,1	6262,4	2,54	1,28	0,85	1,51	3556,0	9818,4	2,01
175	8556,9	593,7	0,0	4030,3	9150,6	4,91	2,27	0,93	2,44	3501,9	12652,5	3,14
176	6912,2	924,9	0,0	4862,0	7837,1	5,33	1,61	0,61	2,64	2538,2	10375,3	2,13
177	7106,3	782,9	0,0	4097,6	7889,2	4,46	1,93	0,90	2,14	3937,2	11826,4	2,89
178	3620,2	521,0	0,0	2597,8	4141,2	3,29	1,59	0,71	2,25	2813,7	6954,9	2,68
179	9114,3	799,2	388,1	5341,2	10301,6	3,53	1,93	0,85	2,27	5821,7	16123,3	3,02
180	4637,5	391,0	0,0	2361,4	5028,5	4,63	2,13	0,75	2,84	2089,5	7118,0	3,01
181	3682,8	446,3	198,9	2425,5	4328,0	4,23	1,78	0,90	1,98	2326,0	6654,0	2,74
182	598,0	90,9	44,2	327,9	733,1	8,77	2,24	0,60	3,73	168,0	901,1	2,75
183	2110,5	193,3	0,0	1364,4	2303,8	4,02	1,69	0,75	2,25	863,5	3167,3	2,32
184	1161,2	376,1	0,0	1180,8	1537,3	3,89	1,30	0,69	1,89	758,1	2295,4	1,94
185	5039,8	416,6	0,0	2528,0	5456,4	3,68	2,16	0,96	2,25	2208,3	7664,7	3,03

R. br.	Podatci o proračunskoj potrebnoj toplinskoj energiji za grijanje (QH,nd,cal): Godišnja proračunska potrebna toplinska energija za grijanje - QH,nd,cal (KWh/god)	Godišnja proračunska specifična potrebna toplinska energija za grijanje - Q'H,nd,cal (KWh/m2 god)	Dopuštena vrijednost potrebne toplinske energije za grijanje - Q'H,nd,dop (KWh/m2 god)	Usporedba specifične potrebne i dopuštene potrebne toplinske energije za grijanje	Godišnja proračunska potrebna toplinska energija za grijanje - Q''H,nd,ca (KWh/m3 god)	Dopuštena vrijednost potrebne toplinske energije za grijanje - Q''H,nd,dop (KWh/m3 god)	Usporedba potrebne i dopuštene vrijednosti toplinske energije za grijanje	Energetski razred
163	208624	74,00	62,05	1,19	17,83	19,85	0,90	B
164	63904	34,23	71,96	0,48	9,98	23,03	0,43	A
165	111194	27,59	61,38	0,45	5,20	19,64	0,26	A
166	268878	79,33	63,30	1,25	18,05	20,26	0,89	B
167	151626	84,24	79,22	1,06	24,46	25,35	0,96	B
168	301348	122,25	64,67	1,89	28,81	20,69	1,39	C
169	58562	118,64	88,18	1,35	33,13	28,22	1,17	C
170	63733	104,77	88,65	1,18	33,13	28,37	1,17	C
171	75154	62,62	61,47	1,02	10,62	19,67	0,54	B
172	31239	87,19	84,23	1,04	28,59	26,95	1,06	B
173	131414	94,14	71,62	1,31	18,00	22,92	0,79	B
174	130809	53,07	71,57	0,74	15,92	22,90	0,70	B
175	225142	120,82	66,98	1,80	28,19	21,43	1,32	C
176	109127	74,21	90,30	0,82	21,51	28,90	0,74	B
177	151601	85,76	68,27	1,26	19,61	21,85	0,90	B
178	160691	127,67	71,20	1,79	36,30	22,78	1,59	C
179	324293	111,03	60,55	1,83	23,05	19,37	1,19	C
180	129769	119,56	66,88	1,79	27,63	21,40	1,29	C
181	124286	121,43	68,69	1,77	27,57	21,98	1,25	C
182	12394	148,25	92,85	1,60	38,10	29,71	1,28	D
183	68881	120,32	66,40	1,81	24,91	21,25	1,17	C
184	33295	84,23	73,37	1,15	17,74	23,48	0,76	B
185	133925	90,25	65,35	1,38	25,06	20,91	1,20	B

R. br.	Podatci o proračunskoj isporučenoj toplinskoj energiji za grijanje (QH,del,cal): Godišnja proračunska potrebna toplinska energija za grijanje - QH,nd,cal (KWh/god)	Stupanj učinkovitosti sustava grijanja	Godišnja proračunska isporučena toplinska energija za grijanje - QH,del,cal (KWh/god)	Godišnja proračunska specifična isporučena toplinska energija za grijanje - Q'H,del,cal (KWh/m2 god)	Usporedba stvarne i proračunske isporučene toplinske energije za grijanje	Godišnji proračunski trošak isporučene toplinske energije - CQH,del,cal (KM/god)	Godišnji proračunski specifični trošak isporučene toplinske energije - C'QH,del,cal (KM/m2god)
163	208624	0,780	267467	94,87	0,86	37367,3	13,3
164	63904	0,800	79880	42,79	1,14	12297,6	6,6
165	111194	0,860	129295	32,09	0,50	7956,6	2,0
166	268878	0,710	378701	111,73	0,42	60510,3	17,9
167	151626	0,700	216609	120,34	0,90	44275,8	24,6
168	301348	0,677	445123	180,58	0,79	88758,2	36,0
169	58562	0,480	122004	247,17	0,87	19842,2	40,2
170	63733	0,697	91439	150,32	1,98	3970,8	6,5
171	75154	0,850	88416	73,67	0,95	14484,5	12,1
172	31239	0,930	33590	93,75	0,87	8162,3	22,8
173	131414	0,860	152807	109,46	0,55	24376,0	17,5
174	130809	0,790	165581	67,17	0,89	28209,2	11,4
175	225142	0,700	321631	172,60	0,57	16729,7	9,0
176	109127	0,760	143588	97,64	0,67	25414,4	17,3
177	151601	0,620	244518	138,32	0,91	12127,3	6,9
178	160691	0,830	193604	153,82	0,39	32706,8	26,0
179	324293	0,850	381521	130,63	0,27	62122,2	21,3
180	129769	0,630	205983	189,78	0,52	10570,7	9,7
181	124286	0,600	207143	202,39	0,70	10352,9	10,1
182	12394	0,530	23385	279,72	1,31	1169,2	14,0
183	68881	0,790	87191	152,30	0,46	18907,4	33,0
184	33295	1,000	33295	84,23	0,16	3285,1	8,3
185	133925	0,880	152188	102,55	0,64	24772,8	16,7

Prilog 2 – Korelacijska analiza neovisnih i ovisnih varijabli ulaznog seta podataka školskih zgrada u FBiH iz uzorka

Varijable	Broj stupanj dana u sezoni grijanja (SDG)	Srednja mjesečna temperatura u sezoni grijanja	Broj korisnika	Broj korisnika po Ak	Godina izgradnje	Školska dvorana (DA=1/NE=0)	Korisna površina Ak (m2)	Volumen grijanog dijela zgrade Ve (m3)	Površina ovojnice A (m2)	Faktor oblika f=A/Ak	Faktor kompaktnosti fo=A/Ve	Ukupna površina zidova (m2)	Ukupna površina podova (m2)	Ukupna površina stropva (m2)	Ukupna površina otvora (m2)	Prosječni U (W/m2K) za zidove	Prosječni U (W/m2K) za podove	Prosječni U (W/m2K) za stropove	Prosječni U (W/m2K) za otvore	Prosječni "U" (W/m2K) ovojnice	Koeficijent Htr (W/K)	Koeficijent Ht' (W/m2K)	Koeficijent H=Htr+Hve (W/m2K)	Koeficijent H'=H'tr+H've (W/m2K)	Vrsta energenta	Stupanj učinkovitosti sustava grijanja	Režim rada (dnevno sati)	Jedinični trošak energenata za grijanje UCQH,del (KM/kWh)	Godišnja isporučena energija Qh,del (KWh/god)	Godišnji trošak toplinske energije za grijanje CQH,del (KM/god)	Godišnja proračunska potrebna energija QH,nd,cal (KWh/god)	Godišnja proračunska specifična potrebna energija Q'H,nd,cal (KWh/m2god)	Godišnja proračunska isporučena energija QH,del,cal (KWh/god)	Godišnja proračunskaspecifična isporučena energija Q'H,del,cal (KWhm2/god)	Godišnji proračunski trošak toplinske energije za grijanje CQH,del,cal (KM/god)	Godišnji specifični proračunski trošak toplinske energije za grijanje C'QH,del,cal (KM/m2god)
	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X16	X17	X18	X19	X20	X21	X22	X23	X24	X25	X26	X27	X28	Y1	Y2	Y0,cal	Y0,cal,spec	Y1,cal	Y1,cal,spec	Y2,cal	Y2,cal,spec
X1	1,000	-0,947	0,258	0,046	-0,110	0,301	0,304	0,264	0,332	-0,178	-0,158	0,294	0,275	0,299	0,304	-0,195	-0,060	-0,172	0,015	-0,177	0,246	-0,223	0,314	-0,074	0,087	0,065	0,436	-0,190	0,511	0,354	0,598	0,556	0,578	0,439	0,373	0,251
X2	-0,947	1,000	-0,235	-0,026	0,131	-0,322	-0,274	-0,244	-0,302	0,185	0,173	-0,288	-0,242	-0,268	-0,261	0,162	0,066	0,171	0,025	0,185	-0,214	0,232	-0,283	0,079	-0,139	-0,077	-0,372	0,112	-0,438	-0,333	-0,557	-0,531	-0,531	-0,406	-0,384	-0,309
X3	0,258	-0,235	1,000	0,453	0,021	0,140	0,705	0,639	0,626	-0,416	-0,335	0,524	0,530	0,575	0,592	-0,190	-0,236	-0,154	0,010	-0,254	0,501	-0,201	0,607	-0,025	0,128	0,144	0,342	0,041	0,585	0,543	0,528	-0,062	0,474	-0,119	0,397	-0,050
X4	0,046	-0,026	0,453	1,000	0,031	-0,211	-0,159	-0,179	-0,164	0,167	0,164	-0,176	-0,157	-0,116	-0,115	-0,015	-0,080	-0,052	0,096	-0,072	-0,157	0,017	-0,156	-0,001	-0,078	-0,213	0,237	-0,078	0,060	0,010	-0,101	0,154	-0,077	0,234	-0,124	-0,006
X5	-0,110	0,131	0,021	0,031	1,000	-0,034	-0,003	-0,026	-0,077	-0,010	-0,001	-0,264	-0,003	0,000	0,056	-0,078	-0,101	-0,139	-0,166	-0,145	-0,186	-0,153	-0,157	-0,177	-0,063	-0,040	-0,157	0,029	-0,180	-0,122	-0,333	-0,410	-0,300	-0,294	-0,177	-0,234
X6	0,301	-0,322	0,140	-0,211	-0,034	1,000	0,291	0,380	0,436	-0,157	-0,264	0,405	0,396	0,378	0,326	-0,075	-0,060	-0,055	-0,155	-0,122	0,417	-0,126	0,415	-0,033	0,099	0,090	0,240	0,039	0,266	0,186	0,350	0,075	0,337	0,002	0,278	0,120
X7	0,304	-0,274	0,705	-0,159	-0,003	0,291	1,000	0,941	0,902	-0,558	-0,500	0,779	0,799	0,797	0,802	-0,210	-0,196	-0,130	-0,046	-0,228	0,739	-0,237	0,865	-0,022	0,184	0,232	0,245	0,062	0,622	0,608	0,723	-0,133	0,650	-0,219	0,570	-0,036
X8	0,264	-0,244	0,639	-0,179	-0,026	0,380	0,941	1,000	0,937	-0,453	-0,576	0,801	0,824	0,863	0,790	-0,171	-0,226	-0,159	-0,088	-0,269	0,752	-0,259	0,881	-0,039	0,204	0,237	0,252	0,069	0,560	0,551	0,712	-0,090	0,644	-0,183	0,568	0,003
X9	0,332	-0,302	0,626	-0,164	-0,077	0,436	0,902	0,937	1,000	-0,327	-0,357	0,832	0,913	0,927	0,811	-0,166	-0,153	-0,202	-0,064	-0,254	0,787	-0,317	0,892	-0,151	0,167	0,243	0,326	0,026	0,598	0,548	0,746	-0,013	0,676	-0,125	0,552	0,008
X10	-0,178	0,185	-0,416	0,167	-0,010	-0,157	-0,558	-0,453	-0,327	1,000	0,695	-0,304	-0,243	-0,249	-0,424	0,175	0,198	-0,079	0,074	0,087	-0,340	-0,031	-0,409	-0,254	-0,198	-0,198	-0,186	-0,170	-0,359	-0,364	-0,329	0,355	-0,299	0,419	-0,315	0,025
X11	-0,158	0,173	-0,335	0,164	-0,001	-0,264	-0,500	-0,576	-0,357	0,695	1,000	-0,329	-0,264	-0,315	-0,378	0,172	0,307	-0,020	0,089	0,205	-0,340	0,049	-0,437	-0,249	-0,182	-0,196	-0,133	-0,153	-0,262	-0,308	-0,326	0,141	-0,305	0,197	-0,334	-0,066
X12	0,294	-0,288	0,524	-0,176	-0,264	0,405	0,779	0,801	0,832	-0,304	-0,329	1,000	0,609	0,626	0,656	-0,093	-0,030	-0,035	-0,036	-0,087	0,807	-0,087	0,848	0,045	0,138	0,141	0,264	-0,015	0,597	0,458	0,765	0,138	0,715	0,026	0,505	0,071
X13	0,275	-0,242	0,530	-0,157	-0,003	0,396	0,799	0,824	0,913	-0,243	-0,264	0,609	1,000	0,876	0,661	-0,192	-0,197	-0,215	-0,043	-0,283	0,624	-0,399	0,743	-0,252	0,106	0,233	0,244	0,030	0,474	0,472	0,613	-0,053	0,548	-0,144	0,474	-0,017
X14	0,299	-0,268	0,575	-0,116	0,000	0,378	0,797	0,863	0,927	-0,249	-0,315	0,626	0,876	1,000	0,686	-0,161	-0,171	-0,288	-0,100	-0,322	0,631	-0,408	0,763	-0,248	0,141	0,253	0,334	0,015	0,502	0,477	0,636	-0,047	0,574	-0,146	0,469	-0,021
X15	0,304	-0,261	0,592	-0,115	0,056	0,326	0,802	0,790	0,811	-0,424	-0,378	0,656	0,661	0,686	1,000	-0,123	-0,144	-0,167	-0,034	-0,183	0,715	-0,170	0,778	-0,028	0,251	0,246	0,318	0,106	0,528	0,564	0,554	-0,164	0,475	-0,253	0,506	-0,014
X16	-0,195	0,162	-0,190	-0,015	-0,078	-0,075	-0,210	-0,171	-0,166	0,175	0,172	-0,093	-0,192	-0,161	-0,123	1,000	0,238	0,042	0,047	0,406	0,099	0,424	-0,029	0,292	-0,245	-0,218	0,024	-0,202	-0,045	-0,225	-0,113	0,069	-0,059	0,112	-0,232	-0,129
X17	-0,060	0,066	-0,236	-0,080	-0,101	-0,060	-0,196	-0,226	-0,153	0,198	0,307	-0,030	-0,197	-0,171	-0,144	0,238	1,000	0,285	0,041	0,787	0,093	0,397	-0,051	0,220	-0,146	-0,164	-0,116	-0,094	-0,116	-0,174	-0,020	0,178	0,022	0,204	-0,081	0,078
X18	-0,172	0,171	-0,154	-0,052	-0,139	-0,055	-0,130	-0,159	-0,202	-0,079	-0,020	-0,035	-0,215	-0,288	-0,167	0,042	0,285	1,000	0,038	0,722	0,289	0,816	0,097	0,702	-0,171	-0,263	-0,213	-0,032	-0,108	-0,193	0,075	0,207	0,137	0,233	0,040	0,148
X19	0,015	0,025	0,010	0,096	-0,166	-0,155	-0,046	-0,088	-0,064	0,074	0,089	-0,036	-0,043	-0,100	-0,034	0,047	0,041	0,038	1,000	0,211	0,069	0,233	0,107	0,401	-0,177	-0,125	0,075	-0,290	0,216	0,051	0,138	0,321	0,153	0,321	-0,082	-0,118
X20	-0,177	0,185	-0,254	-0,072	-0,145	-0,122	-0,228	-0,269	-0,254	0,087	0,205	-0,087	-0,283	-0,322	-0,183	0,406	0,787	0,722	0,211	1,000	0,257	0,837	0,042	0,665	-0,249	-0,289	-0,177	-0,157	-0,111	-0,254	0,022	0,256	0,089	0,289	-0,083	0,070
X21	0,246	-0,214	0,501	-0,157	-0,186	0,417	0,739	0,752	0,787	-0,340	-0,340	0,807	0,624	0,631	0,715	0,099	0,093	0,289	0,069	0,257	1,000	0,281	0,950	0,374	0,056	0,055	0,272	-0,049	0,574	0,406	0,788	0,188	0,764	0,084	0,527	0,074
X22	-0,223	0,232	-0,201	0,017	-0,153	-0,126	-0,237	-0,259	-0,317	-0,031	0,049	-0,087	-0,399	-0,408	-0,170	0,424	0,397	0,816	0,233	0,837	0,281	1,000	0,063	0,875	-0,199	-0,296	-0,121	-0,120	-0,075	-0,224	0,014	0,245	0,079	0,273	-0,080	0,068
X23	0,314	-0,283	0,607	-0,156	-0,157	0,415	0,865	0,881	0,892	-0,409	-0,437	0,848	0,743	0,763	0,778	-0,029	-0,051	0,097	0,107	0,042	0,950	0,063	1,000	0,273	0,108	0,141	0,314	-0,028	0,656	0,529	0,857	0,147	0,810	0,027	0,603	0,066
X24	-0,074	0,079	-0,025	-0,001	-0,177	-0,033	-0,022	-0,039	-0,151	-0,254	-0,249	0,045	-0,252	-0,248	-0,028	0,292	0,220	0,702	0,401	0,665	0,374	0,875	0,273	1,000	-0,163	-0,212	0,009	-0,125	0,132	-0,024	0,231	0,297	0,278	0,285	0,088	0,094
X25	0,087	-0,139	0,128	-0,078	-0,063	0,099	0,184	0,204	0,167	-0,198	-0,182	0,138	0,106	0,141	0,251	-0,245	-0,146	-0,171	-0,177	-0,249	0,056	-0,199	0,108	-0,163	1,000	0,692	0,139	0,666	-0,029	0,530	0,112	-0,161	-0,072	-0,383	0,497	0,482
X26	0,065	-0,077	0,144	-0,213	-0,040	0,090	0,232	0,237	0,243	-0,198	-0,196	0,141	0,233	0,253	0,246	-0,218	-0,164	-0,263	-0,125	-0,289	0,055	-0,296	0,141	-0,212	0,692	1,000	0,153	0,502	-0,011	0,413	0,126	-0,200	-0,125	-0,518	0,299	0,223
X27	0,436	-0,372	0,342	0,237	-0,157	0,240	0,245	0,252	0,326	-0,186	-0,133	0,264	0,244	0,334	0,318	0,024	-0,116	-0,213	0,075	-0,177	0,272	-0,121	0,314	0,009	0,139	0,153	1,000	-0,196	0,522	0,352	0,388	0,240	0,346	0,133	0,118	-0,034
X28	-0,190	0,112	0,041	-0,078	0,029	0,039	0,062	0,069	0,026	-0,170	-0,153	-0,015	0,030	0,015	0,106	-0,202	-0,094	-0,032	-0,290	-0,157	-0,049	-0,120	-0,028	-0,125	0,666	0,502	-0,196	1,000	-0,360	0,419	-0,136	-0,331	-0,272	-0,473	0,555	0,696
Y1	0,511	-0,438	0,585	0,060	-0,180	0,266	0,622	0,560	0,598	-0,359	-0,262	0,597	0,474	0,502	0,528	-0,045	-0,116	-0,108	0,216	-0,111	0,574	-0,075	0,656	0,132	-0,029	-0,011	0,522	-0,360	1,000	0,574	0,725	0,242	0,727	0,188	0,247	-0,178
Y2	0,354	-0,333	0,543	0,010	-0,122	0,186	0,608	0,551	0,548	-0,364	-0,308	0,458	0,472	0,477	0,564	-0,225	-0,174	-0,193	0,051	-0,254	0,406	-0,224	0,529	-0,024	0,530	0,413	0,352	0,419	0,574	1,000	0,519	-0,002	0,372	-0,169	0,719	0,388
Y0,cal	0,598	-0,557	0,528	-0,101	-0,333	0,350	0,723	0,712	0,746	-0,329	-0,326	0,765	0,613	0,636	0,554	-0,113	-0,020	0,075	0,138	0,022	0,788	0,014	0,857	0,231	0,112	0,126	0,388	-0,136	0,725	0,519	1,000	0,490	0,958	0,326	0,640	0,219
Y0,cal,spec	0,556	-0,531	-0,062	0,154	-0,410	0,075	-0,133	-0,090	-0,013	0,355	0,141	0,138	-0,053	-0,047	-0,164	0,069	0,178	0,207	0,321	0,256	0,188	0,245	0,147	0,297	-0,161	-0,200	0,240	-0,331	0,242	-0,002	0,490	1,000	0,529	0,922	0,173	0,346
Y1,cal	0,578	-0,531	0,474	-0,077	-0,300	0,337	0,650	0,644	0,676	-0,299	-0,305	0,715	0,548	0,574	0,475	-0,059	0,022	0,137	0,153	0,089	0,764	0,079	0,810	0,278	-0,072	-0,125	0,346	-0,272	0,727	0,372	0,958	0,529	1,000	0,458	0,528	0,134
Y1,cal,spec	0,439	-0,406	-0,119	0,234	-0,294	0,002	-0,219	-0,183	-0,125	0,419	0,197	0,026	-0,144	-0,146	-0,253	0,112	0,204	0,233	0,321	0,289	0,084	0,273	0,027	0,285	-0,383	-0,518	0,133	-0,473	0,188	-0,169	0,326	0,922	0,458	1,000	-0,007	0,173
Y2,cal	0,373	-0,384	0,397	-0,124	-0,177	0,278	0,570	0,568	0,552	-0,315	-0,334	0,505	0,474	0,469	0,506	-0,232	-0,081	0,040	-0,082	-0,083	0,527	-0,080	0,603	0,088	0,497	0,299	0,118	0,555	0,247	0,719	0,640	0,173	0,528	-0,007	1,000	0,723
Y2,cal,spec	0,251	-0,309	-0,050	-0,006	-0,234	0,120	-0,036	0,003	0,008	0,025	-0,066	0,071	-0,017	-0,021	-0,014	-0,129	0,078	0,148	-0,118	0,070	0,074	0,068	0,066	0,094	0,482	0,223	-0,034	0,696	-0,178	0,388	0,219	0,346	0,134	0,173	0,723	1,000
	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X16	X17	X18	X19	X20	X21	X22	X23	X24	X25	X26	X27	X28	Y1	Y2	Y0,cal	Y0,cal,spec	Y1,cal	Y1,cal,spec	Y2,cal	Y2,cal,spec

Legenda: Crvenom bojom označene statistički značajne korelacije pri p < 0,05

Curriculum vitae

Dragan Katić rođen je 29. siječnja 1978. god. u Doboju, Bosna i Hercegovina. Završio je Opću gimnaziju u Usori (Bosna i Hercegovina) 1996. godine, a 2001. godine završio je diplomski sveučilišni studij građevinarstva, opći smjer, na Građevinskom fakultetu Sveučilišta u Mostaru (Bosna i Hercegovina). 29. lipnja 2010. godine završio je poslijediplomski sveučilišni znanstveni studij za magistra znanosti, smjer organizacija građenja, na Građevinskom fakultetu Sveučilišta u Zagrebu. Od akademske 2017./2018. upisan na poslijediplomski sveučilišni studij građevinarstva, modul organizacija i tehnologija građenja, na Građevinskom i arhitektonskom fakultetu u Osijeku. Od 2001. godine do danas uposlen na Građevinskom fakultetu Sveučilišta u Mostaru i radi kao asistent i viši asistent na kolegijima Organizacija građenja, Organizacija i tehnologija građenja, Upravljanje projektima, Fizika zgrade, Energetska učinkovitost, Otpornost materijala 1 i Otpornost materijala 2. Završio je program osposobljavanja i usavršavanja za energetske preglede i energetsko certificiranje zgrada – Modul 1. Certificiran je za zvanje Menadžera za energetsku učinkovitost prema DIN EN ISO 50001. Završio je seminar pod nazivom ''Upravljanje projektima u građevinarstvu i FIDIC – crvena, roza i žuta knjiga'' organiziran od strane Udruženja konzultanata inženjera BiH. Član je Hrvatske udruge za organizaciju građenja (HUOG). Sudjelovao je u preko 100 stručnih projekata vezanih za projektiranje, reviziju i nadzor nad građenjem građevinskih projekata.