

Primljen / Received: 10.12.2025.

Ispravljen / Corrected: 31.3.2026.

Prihvaćen / Accepted: 7.5.2026.

Dostupno online / Available online: 10.10.2026.

Potpora odlučivanju o energetske učinkovitosti projektiranju pročelja

Autori:

Dr.sc. **Hilal Parlak Arslan**, dipl.ing.arh.

Sveučilište Ondokuz Mayıs, Turska

Arhitektonski fakultet

hilal.parlak@omu.edu.tr

Autor za korespondenciju

Prof.dr.sc. **Gül Koçlar Oral**, dipl.ing.arh.

Tehničko sveučilište u Istanbulu, Turska

Arhitektonski fakultet

kgul@itu.edu.tr

Prethodno priopćenje

Hilal Parlak Arslan, Gül Koçlar Oral

Potpora odlučivanju o energetske učinkovitosti projektiranju pročelja

Cilj ovog istraživanja bio je procijeniti utjecaj parametara projektiranja pročelja stambenih zgrada orijentiranih prema sjeveru, čija slikovita vizura ima prednost pred klimatski najpovoljnijom orijentacijom, te razviti projektne smjernice kojima se, unatoč prostornim ograničenjima, može postići optimalna energetska učinkovitost. U tu je svrhu razvijen model za potporu odlučivanju kojim se analizira osjetljivost projektnih parametara pročelja na potrebe za grijanjem i hlađenjem te na emisije CO₂, uz istodobno određivanje optimalnog rješenja za pročelje. Model se temelji na tri osnovna fazama: izradi modela zgrade, primjeni analize osjetljivosti te postupku optimizacije.

Ključne riječi:

stambene zgrade, energetske učinkovite pročelje, energetske modeliranje, analiza osjetljivosti, optimizacija

Research Paper

Hilal Parlak Arslan, Gül Koçlar Oral

Decision support for energy-efficient façade design

This study aimed to evaluate the impact of façade design parameters in north-oriented residential buildings, where scenic views take priority over ideal climatic orientation, and develop design strategies that ensure optimal energy performance under these specific contextual limitations. A decision-support model is proposed to analyse the sensitivity of façade design parameters to heating and cooling loads as well as CO₂ emission values, and to identify optimal façade solutions through three main stages: creating the building model, applying the sensitivity analysis method, and applying the optimisation method.

Key words:

residential buildings, energy-efficient façade, energy modelling, sensitivity analysis, optimisation

1. Uvod

Energetski izazovi povezani sa zadovoljavanjem stambenih potreba nameću potrebu za postizanjem visoke energetske učinkovitosti u izgradnji stambenih zgrada. Kako bi se tijekom projektiranja postigla željena energetska svojstva, potrebno je razmotriti i usporediti razna projektna rješenja. Sustavi za potporu odlučivanju važan su alat za unaprijeđenje energetske svojstava zgrada, osobito u ranim fazama projektiranja [1]. Budući da se upravo u toj fazi donose odluke koje imaju najveći utjecaj na konačna svojstva građevine i troškove njezine izvedbe, donošenje projektnih odluka potrebno je temeljiti na odgovarajućim analitičkim alatima koji omogućuju usmjeravanje projektiranja prema učinkovitijim rješenjima [2]. Radi potrebe za pouzdanim predviđanjem učinaka projektnih odluka, u procjeni energetske svojstava zgrada sve se češće primjenjuje analiza osjetljivosti [3]. Riječ je o metodi kojom se određuje utjecaj pojedinih ulaznih parametara na rezultate analize te identificiraju ključni čimbenici koji određuju energetske učinkovitosti građevine. Kako bi se tijekom projektiranja unaprijedilo odlučivanje, analiza osjetljivosti integrirana je u višekriterijske sustave odlučivanja i postupke višeciljne optimizacije radi određivanja parametara koji najviše utječu na potrošnju energije te raspona njihovih optimalnih vrijednosti [4, 5]. Ulukavak Harputlugil [6] razvio je model projektnih smjernica koje projektantima pomažu u poboljšanju svojstava zgrada na temelju analize klimatskih područja u Turskoj. Tian [5] ističe da analiza osjetljivosti omogućuje prepoznavanje ključnih varijabli koje utječu na energetske učinkovitost zgrade, kako na temelju simulacijskih modela tako i na temelju eksperimentalnih opažanja. Yıldız i sur. [7] primijenili su analizu osjetljivosti pri određivanju godišnje potrebe za energijom za hlađenje niskih stambenih zgrada u vrućoj i vlažnoj klimi Turske. Gerçek i Arsan [8] analizirali su utjecaj projektnih parametara na godišnje potrebe za energijom za grijanje i hlađenje stambenih zgrada u uvjetima sadašnje i buduće klime u području s vrućom i vlažnom klimom. Uz analizu osjetljivosti u sustavima za potporu odlučivanju važnu ulogu ima i optimizacija jer omogućuje istodobno razmatranje više, često međusobno suprotstavljenih ciljeva povezanih s energetske učinkovitošću zgrada. Nguyen [9] primijenio je simulacijski utemeljenu optimizaciju kako bi za tri najzastupljenija tipa stambenih zgrada u Vijetnamu odredio optimalne kombinacije projektnih rješenja za svaku klimatsku zonu na temelju ključnih projektnih varijabli utvrđenih analizom osjetljivosti. Şenel Solmaz [10] razvio je simulacijski utemeljen postupak višeciljne optimizacije za određivanje optimalnih parametara ovojnice uredske zgrade u Izmiru te rezultate analizirao u sklopu cjelovitog sustava za potporu odlučivanju. Mangan [11] razvio je mrežni alat za potporu odlučivanju usmjeren na analizu energije i troškova, namijenjen povećanju razine osviještenosti u stambenom sektoru i poticanju gradnje održivih stambenih zgrada. Alat razvijen u tome istraživanju, kojim se analiziraju projektne alternative koje istodobno zadovoljavaju međusobno suprotstavljene ciljeve, vrijedan

je temelj za učinkovitu potporu donosiocima odluka. Velik broj optimizacijskih istraživanja usmjeren je na optimiranje projektiranja pročelja. Gagne i Andersen [12] primijenili su genetski algoritam za optimiranje parametara ostakljenja, veličine otvora na pročelju i geometrijskih značajki elemenata za zasjenjivanje s obzirom na dnevno osvjetljenje prostora. Jin [13] razvio je optimizacijski model kojim su dobivena projektna rješenja pročelja s boljim pokazateljima emisija CO₂ i troškova u odnosu na rješenja dobivena konvencionalnim postupkom projektiranja. Kültür i sur. [14] predstavili su cjelovit alat za potporu odlučivanju utemeljen na međusobnoj povezanosti svojstava pročelja, projektnih parametara i uvjeta primjene, namijenjen potpori odlučivanju u ranim fazama projektiranja pročelja. Radi optimiranja svojstava zgrada razvijeni su brojni programski alati, među kojima su BEopt, GenOpt, Op-E-Plus, MOBO i jEPlus+EA te drugi optimizacijski alati u područjima pasivnog projektiranja, potrošnje energije i procjene utjecaja na okoliš. Tokarik i sur. [15, 16] primijenili su program jEPlus za višeciljnu optimizaciju pasivnih mjera energetske učinkovitosti visokoučinkovite obiteljske kuće u Torontu radi određivanja konfiguracija koje omogućuju optimalna svojstva zgrade i troškove tijekom njezina životnog vijeka. Radi smanjenja potrošnje energije, Kahsay i sur. [17] primijenili su simulacijski utemeljenu optimizaciju u okružju jEPlus+EA kako bi odredili najpovoljnije dimenzije i raspored prozora u visokogradnji.

Brojna istraživanja ističu važnost primjene alata za potporu odlučivanju u ranim fazama projektiranja radi poboljšanja energetske učinkovitosti zgrada, jer projektantske odluke donesene u toj fazi imaju znatan i dugotrajan utjecaj na ukupnu potrošnju energije u zgradi [18, 19]. Međutim, postoji primjetan nedostatak u potpori odlučivanju kada kontekstualna ograničenja ograničavaju primjenu strategija klimatskog projektiranja. Kada okolišni ili lokacijski parametri ograničavaju donošenje optimalnih odluka o orijentaciji, tada je potencijal za smanjenje energetske gubitaka pasivnim projektiranjem osobito ograničen [20, 21]. Relevantan primjer može se uočiti u sjevernim regijama Turske (npr. regija Crnog mora), gdje su kuće često orijentirane prema sjeveru zbog slikovitog pogleda na more. Zbog toga pročelje okrenuto prema sjeveru postaje primarno sučelje koje utječe na energetske učinkovitost. S obzirom na to da ovojnica zgrade, posebno pročelje, većinom prenosi toplinu između unutarnjeg i vanjskog okružja, rane projektantske odluke o pročeljima u takvim kontekstualno ograničenim zgradama ključne su za optimizaciju toplinske učinkovitosti [22-24]. Zato je razumijevanje utjecaja parametara projektiranja pročelja na energetske opterećenja u zgradama s ograničenjima u orijentaciji ključno za postizanje energetske učinkovitosti tijekom faze rada. U tome smislu, cilj je ovog istraživanja procijeniti utjecaj parametara projektiranja pročelja u stambenim zgradama orijentiranim prema sjeveru i razviti strategije projektiranja koje osiguravaju optimalnu energetske učinkovitost pod tim specifičnim kontekstualnim ograničenjima.

2. Materijali i metode

Cilj modela jest razviti sustav za potporu odlučivanju koji omogućuje optimiranje projektnih rješenja pročelja na temelju vrednovanja projektnih parametara pročelja te pruža potporu u donošenju utemeljenih projektantskih odluka radi poboljšanja energetske učinkovitosti stambenih zgrada. U tu su svrhu definirani sljedeći ciljevi:

- utvrditi projektna rješenja kojima se postižu optimalna energetska svojstva stambenih zgrada
- omogućiti projektiranje stambenih zgrada s optimalnom energetske učinkovitosti primjenom razvijenog modela u fazi projektiranja.

Faze predloženog pristupa, čiji je cilj vrednovanje energetske učinkovitosti stambenih zgrada s obzirom na projektne parametre pročelja, prikazane su u nastavku i shematski objašnjene na slici 1. [25]. Izrada modela zgrade obuhvaća primjenu:

- metode analize osjetljivosti
- metode optimizacije.


Razvijeni pristup vrednovanju energetske svojstva stambenih zgrada može se promatrati kao sastavni dio faze projektiranja te je primjenjiv na nove zgrade. Zato je razvijeni model utemeljen na referentnom modelu stambene zgrade.

2.1. Izrada modela zgrade


Faza izrade modela zgrade obuhvaća definiranje modela zgrade i razvoj projektnih varijanti. Pri definiranju modela uzeti su u obzir parametri povezani s korisnicima, klimatskim uvjetima i zgradama [26]. Kao referentni model odabrana je stambena zgrada u pokrajini Samsunu, u Crnomorskoj regiji u Turskoj, koja je dominantno orijentirana prema sjeveru. Za izradu modela primijenjen je računalni program *DesignBuilder*, programsko sučelje za procjenu energetske učinkovitosti zgrada primjenom programa *EnergyPlus* [27].

Parametri povezani s korisnicima određeni su na temelju službenih podataka o strukturi kućanstava u Samsunu. Prosječno kućanstvo čine tri člana: dva roditelja (od kojih je jedan

zaposlen) i jedno dijete [28]. Razina aktivnosti korisnika određena je na 110 W po osobi [29]. Toplinska izolacija odjeće korisnika iznosila je 1 clo u razdoblju grijanja odnosno 0,5 clo u razdoblju hlađenja. Za određivanje klimatskih parametara primijenjena je meteorološka datoteka Tipične meteorološke godine (*Typical Meteorological Year – TMY*) kojom su opisani vanjski klimatski uvjeti u Samsunu [30]. Samsun se odlikuje umjereno vlažnom klimom. Najniža prosječna mjesečna temperatura iznosi 3,9 °C u veljači, a najviša prosječna mjesečna temperatura 27,1 °C u kolovozu. Srednja godišnja temperatura zraka iznosi približno 14,6 °C [31]. Za potrebe modeliranja unutarnjih klimatskih uvjeta sustav grijanja definiran je kao sustav grijanja na prirodni plin kojim se održava temperatura unutarnjeg zraka



Slika 1. Shematski opis predložene metode [25]



Slika 2. Projektne varijante modela zgrade

od 20 °C u razdoblju od 7.00 do 23.00 sata te od 13 °C izvan razdoblja grijanja. Sustav hlađenja definiran je kao zidni *split*-sustav klimatizacije kojim se održava temperatura unutarnjeg zraka od 26 °C u razdoblju od 7.00 do 23.00 sata te od 32 °C izvan razdoblja hlađenja [32]. Za sustav grijanja pretpostavljen je koeficijent učinkovitosti (engl. *Coefficient of Performance* - COP) od 0,85, dok je za rashladni sustav usvojen COP od 4,50, pri čemu se električna energija primjenjuje kao izvor energije [33]. Za projektne parametre koji se odnose na zgradu pretpostavljeno je da se zgrada nalazi na ravnome terenu te da nema okolnih zgrada. Tlocrtne dimenzije zgrade iznose 10

× 10 m, a visina etaže 3 m. Zgrada ima četverostrešni krov i pročelja orijentirana na četiri strane svijeta. Modelirana je kao peterokatna zgrada [34] s po jednim stanom na svakoj etaži, pri čemu je svaka etaža definirana kao zasebna toplinska zona. Analiza se temelji na proračunima provedenima za treći kat, koji čini međukatnu etažu zgrade. Izračunane vrijednosti koeficijenta prolaska topline (U) za neprozirne i prozirne dijelove modela zgrade iznosile su 0,59 W/m²K za vanjski zid, 0,53 W/m²K za podnu ploču, 0,36 W/m²K za krov te 2,40 W/m²K za prozor [35]. U sustavu umjetne rasvjete primijenjena je LED rasvjeta snage 7,5 W/m², čiji je intenzitet osvijetljenja moguće postupno regulirati ovisno o razini dnevnog osvijetljenja. U skladu s namjenom stambene zgrade, snaga električne opreme određena je na 5 W/m². Kao element za zasjenjivanje upotrijebljena je vanjska žaluzina za prozore.

Generirani model zgrade nazvan je Projektna varijanta 1. (A1). Projektne varijante modela zgrade razvijene su kako bi se analizirao utjecaj sjevernog pročelja na energetske učinkovitost zgrade (slika 1.).

Pri provedbi analize vodilo se računa o tome da svaka projektna varijanta ima otvore na sjevernome pročelju, dok su bočna pročelja ostala nepromijenjena, a istočno i zapadno pročelje izvedeni su s različitim konfiguracijama. Razvoj modela zgrade obuhvatio je sljedeće korake:

1. Model zgrade definiran u prvoj fazi označen je kao projektna varijanta A1.
2. Projektne varijante (A2 – A8) razvijene su primjenom različitih konfiguracija neprozirnog dijela pročelja na prvi model (A1).
3. Modeli (A9 – A16) razvijeni su postavljanjem omjera prozirnosti sjevernih pročelja na 80 %, pri čemu su kao polazište poslužile projektne varijante (slika 2.).

U prvome koraku model zgrade označen kao Alternativa 1 (A1) ima sva četiri pročelja otvorena, bez potpuno neprozirnih pročelja.

U drugome koraku na temelju modela A1 razvijen je niz modela (A2 – A8) primjenom različitih konfiguracija neprozirnih pročelja. U tim je projektним varijantama istočno pročelje u modelu A2 u cijelosti neprozirno, neprozirna su i zapadno pročelje u modelu

A3, južno pročelje u modelu A4, južno i istočno pročelje u modelu A5, južno i zapadno pročelje u modelu A6, istočno i zapadno pročelje u modelu A7 te južno, istočno i zapadno pročelje u modelu A8. Pri razvoju tih modela uzeti su u obzir uobičajeni tipovi stambenih zgrada u Samsunu. Iako je u referentnome modelu zgrade izrađenome u programu *DesignBuilder* za sva pročelja usvojen početni omjer prozirnosti od 30 %, tijekom analize omjer prozirnosti svih pročelja mijenjao se u približnome rasponu od 10 % do 80 %, ovisno o vrijednostima parametara definiranim u fazi analize osjetljivosti. Kako bi se procijenio utjecaj ostalih pročelja na ukupna energetska svojstva zgrade u slučaju kada sjeverno pročelje ima visok omjer prozirnosti, kao što je to u primjeru iz Samsuna, razvijen je dodatni skup modela u kojima je omjer prozirnosti sjevernog pročelja zadržan konstantnim. Modeli A9 – A16 odgovaraju konfiguracijama neprozirnih pročelja modela A1 – A8, s tom razlikom da je u tim modelima omjer prozirnosti sjevernog pročelja određen na 80 %. U trećemu koraku razvijeni su modeli A9 – A16 uvođenjem velikih prozirnih otvora na sjeverna pročelja modela A1 – A8. Model A9 ima otvorena pročelja na sve četiri strane, bez potpuno neprozirnih pročelja. Model A10 ima potpuno neprozirno istočno pročelje, model A11 potpuno neprozirno zapadno pročelje, a model A12 potpuno neprozirno južno pročelje. Model A13 ima potpuno neprozirno južno i istočno pročelje, a model A14 potpuno neprozirno južno i zapadno pročelje. U modelu A15 potpuno je neprozirno istočno i zapadno pročelje, a u modelu A16 južno, istočno i zapadno pročelje. U svim modelima od A9 do A16 omjer prozirnosti sjevernog pročelja utvrđen je na 80 %. U tim se modelima omjer prozirnosti ostalih pročelja mijenjao, dok je omjer prozirnosti sjevernog pročelja ostao nepromijenjen.

2.2. Primjena metode analize osjetljivosti

Primjena metode analize osjetljivosti obuhvaća definiranje projektnih parametara, izradu simulacijskih datoteka, provedbu simulacija te određivanje razine utjecaja projektnih parametara na potrebe za energijom. U prvoj fazi analize osjetljivosti projektni parametri definirani su u pet kategorija: orijentacija, prozori, vanjski zidovi, elementi za zasjenjivanje i stopa infiltracije zraka. Parametri definirani u kategoriji prozora obuhvatili su širinu prozora, visinu prozora, koeficijent prolaska Sunčeve topline kroz ostakljenje (engl. *solar heat gain coefficient* - SHGC) i koeficijent prolaska topline prozora (U-vrijednost). U kategoriji vanjskih zidova definirani su debljina toplinsko-izolacijskog materijala, specifični toplinski kapacitet toplinsko-izolacijskog materijala i koeficijent toplinske vodljivosti toplinsko-izolacijskog materijala. U kategoriji elemenata za zasjenjivanje definirani su dubina elementa za zasjenjivanje i njegov kut nagiba. Kategorije orijentacije i stope infiltracije zraka nisu dodatno raščlanjene na pojedinačne parametre. Svi su parametri definirani za svako pročelje pojedinačno (sjeverno, južno, istočno i zapadno), osim orijentacije i stope infiltracije zraka koji su određeni za cijelu zgradu te zato nisu bili vezani uz pojedino pročelje. Raspon vrijednosti pojedinih parametara određen je na temelju

raspona primijenjenih u prethodnim istraživanjima, graničnih vrijednosti građevnih materijala koji se uobičajeno primjenjuju u graditeljstvu te zahtjeva turske norme TS 825 [35]. Budući da vrijednosti odabranih parametara izravno utječu na rezultate analize osjetljivosti, svakom je parametru pridružen što veći broj vrijednosti, što je uzeto u obzir pri tumačenju rezultata. U tablici 1. prikazani su nazivi 38 projektnih parametara obuhvaćenih analizom osjetljivosti, pročelja na koja se odnose, njihove kratice, mjerne jedinice te minimalne i maksimalne vrijednosti kojima je definiran raspon svakog parametra [36].

Među generiranim modelima, model A1 uključuje vrijednosti svih 38 parametara, dok modeli razvijeni primjenom različitih konfiguracija neprozirnih pročelja obuhvaćaju vrijednosti samo dijela tih parametara.

Nakon što su definirani projektni parametri i određen raspon njihovih vrijednosti, za dodjelu vrijednosti parametara pojedinim datotekama tijekom izrade simulacijskih datoteka upotrijebljen je program *JEPlus*. On omogućuje definiranje parametara unutar modela *EnergyPlus* te upravlja simulacijama za generirane parametarske ulazne podatke [16]. Skup uzoraka generiran je primjenom metode uzorkovanja latinskoga hiperkubra (engl. *Latin Hypercube Sampling* – LHS), pri čemu su u program *JEPlus* uneseni projektni parametri i odgovarajući rasponi njihovih vrijednosti. Metoda uzorkovanja latinskoga hiperkubra stratificirana je metoda uzorkovanja kojom se osigurava ravnomjernija pokrivenost cjelokupnog raspona vrijednosti parametara. U njoj se svaki projektni parametar dijeli na određeni broj intervala, unutar kojih se generiraju vrijednosti parametara [37, 38]. Veličina uzorka određena je u skladu s uobičajenom preporukom za primjenu metode uzorkovanja latinskoga hiperkubra, prema kojoj broj uzoraka treba biti između 1,5 i 10 puta veći od broja analiziranih parametara. Zato je veličina uzorka određena kao osmerostruki broj projektnih parametara ($38 \times 8 = 304$) [39]. Takva veličina uzorka primijenjena je samo na model A1, u kojemu su vrijednosti dodijeljene svim projektnim parametrima. Budući da se povećanjem broja neprozirnih pročelja u različitim konfiguracijama smanjuje broj projektnih parametara kojima se dodjeljuju vrijednosti, na te je modele primijenjena odgovarajuće manja veličina uzorka. Rezultati simulacija dobiveni su istodobnom promjenom vrijednosti svih projektnih parametara unutar svakog modela. Pokazatelji uspješnosti razmotreni u toj fazi obuhvatili su godišnju potrebnu energiju za grijanje (kWh), godišnju potrebnu energiju za hlađenje (kWh) i emisije CO₂ (kg). Potrebna energija za grijanje i hlađenje jest količina energije potrebna za održavanje zadanih uvjeta toplinske ugodnosti tijekom godine, odnosno pokazuje godišnju potrebu zgrade za energijom za grijanje i hlađenje prostora. Utjecaj pojedinih projektnih parametara na potrebe za energijom određen je zasebnom procjenom utjecaja svakog parametra na izlazne rezultate primjenom programa *JEPlus+EA* [40].

Dodatni alat, *JEPlus+EA*, razvijen je za optimiranje projekata izrađenih u programu *JEPlus* primjenom genetskih algoritama [40]. Iako je riječ o programu koji se relativno kratko primjenjuje u istraživačkoj zajednici, dosadašnja istraživanja pokazala su

Tablica 1. Parametri primijenjeni u analizi osjetljivosti [35]

Projektni parametar	Pročelje	Kratika	Jedinica	Raspon vrijednosti
Orijentacija		(ORI)	stupanj	0, 45, 315
Širina prozora	Sjeverno pročelje	(WW-N)	m	1,5 – 8,5
	Južno pročelje	(WW-S)	m	1,5 – 8,5
	Istočno pročelje	(WW-E)	m	1,5 – 8,5
	Zapadno pročelje	(WW-W)	m	1,5 – 8,5
Visina prozora	Sjeverno pročelje	(WH-N)	m	1,5 – 2,5
	Južno pročelje	(WH-S)	m	1,5 – 2,5
	Istočno pročelje	(WH-E)	m	1,5 – 2,5
	Zapadno pročelje	(WH-W)	m	1,5 – 2,5
Koeficijent prolaska Sunčeve topline prozora	Sjeverno pročelje	(SHGC-N)	-	0,51 – 0,86
	Južno pročelje	(SHGC-S)	-	0,51 – 0,86
	Istočno pročelje	(SHGC-E)	-	0,51 – 0,86
	Zapadno pročelje	(SHGC-W)	-	0,51 – 0,86
U-vrijednost prozora	Sjeverno pročelje	(Uw-N)	W/m ² K	0,8 – 2,4
	Južno pročelje	(Uw-S)	W/m ² K	0,8 – 2,4
	Istočno pročelje	(Uw-E)	W/m ² K	0,8 – 2,4
	Zapadno pročelje	(Uw-W)	W/m ² K	0,8 – 2,4
Debljina izolacijskog materijala zida	Sjeverno pročelje	(IT-N)	m	0,01 – 0,1
	Južno pročelje	(IT-S)	m	0,01 – 0,1
	Istočno pročelje	(IT-E)	m	0,01 – 0,1
	Zapadno pročelje	(IT-W)	m	0,01 – 0,1
Vrijednost specifične topline materijala za toplinsku izolaciju zida	Sjeverno pročelje	(ISHV-N)	J/kg-K	600 – 2000
	Južno pročelje	(ISHV-S)	J/kg-K	600 – 2000
	Istočno pročelje	(ISHV-E)	J/kg-K	600 – 2000
	Zapadno pročelje	(ISHV-W)	J/kg-K	600 – 2000
Vrijednost toplinske vodljivosti materijala za toplinsku izolaciju zida	Sjeverno pročelje	(ICV-N)	W/mK	0,03 – 0,04
	Južno pročelje	(ICV-S)	W/mK	0,03 – 0,04
	Istočno pročelje	(ICV-E)	W/mK	0,03 – 0,04
	Zapadno pročelje	(ICV-W)	W/mK	0,03 – 0,04
Dubina elementa za zasjenjivanje	Sjeverno pročelje	(SED-N)	m	0,1 – 0,2
	Južno pročelje	(SED-S)	m	0,1 – 0,2
	Istočno pročelje	(SED-E)	m	0,1 – 0,2
	Zapadno pročelje	(SED-W)	m	0,1 – 0,2
Kut elementa za zasjenjivanje	Sjeverno pročelje	(SEA-N)	stupanj	10 – 90
	Južno pročelje	(SEA-S)	stupanj	10 – 90
	Istočno pročelje	(SEA-E)	stupanj	10 – 90
	Zapadno pročelje	(SEA-W)	stupanj	10 – 90
Stopa infiltracije zraka		(AIR)	ach	0,1 – 1,2

da omogućuje pouzdanu višeciljnu optimizaciju uz jednostavno korisničko sučelje i razmjerno male računalne zahtjeve [41–44]. U tablica 2. prikazano je pet najutjecajnijih projektnih parametara pročelja nakon njihova rangiranja prema razini utjecaja na potrebnu energiju za grijanje, potrebnu energiju za hlađenje i na vrijednosti emisija CO₂ (A1 – A16). Parametri u tablici 2. označeni su kraticama navedenima u tablici 1. Iz tablice vidljivo je da je, s obzirom na potrebnu energiju za grijanje, stopa infiltracije zraka (AIR) dosljedno utvrđena kao najutjecajniji parametar u svim modelima. Analizom pet najutjecajnijih parametara za potrebnu energiju za grijanje uočeno je da prevladavaju stopa infiltracije zraka (AIR), orijentacija (ORI), širina prozora (WW) u kategoriji prozora, koeficijent prolaska Sunčeve topline (SHGC), koeficijent prolaska topline prozora (U-vrijednost) (UW) i debljina toplinsko-izolacijskog materijala (IT) iz kategorije zidova. Analizom utjecaja navedenih parametara na potrebnu energiju za hlađenje utvrđeno je da je širina prozora (WW) dosljedno svrstana među najutjecajnije parametre u svim modelima. Među pet najutjecajnijih parametara za potrebnu energiju za hlađenje

najčešće se pojavljuju stopa infiltracije zraka (AIR), orijentacija (ORI), širina prozora (WW) u kategoriji prozora, visina prozora (WH), koeficijent prolaska Sunčeve topline (SHGC) i koeficijent prolaska topline prozora (U-vrijednost) (UW). Analizom utjecaja parametara na emisije CO₂ utvrđeno je da je stopa infiltracije zraka (AIR) najutjecajniji parametar u svim modelima. Među pet najutjecajnijih parametara za emisije CO₂ najčešće se nalaze stopa infiltracije zraka (AIR), orijentacija (ORI), širina prozora (WW) u kategoriji prozora, koeficijent prolaska Sunčeve topline (SHGC), koeficijent prolaska topline prozora (U-vrijednost) (UW) te debljina toplinsko-izolacijskog materijala (IT) iz kategorije zidova. Rezultati analize osjetljivosti iz tablice 2. pokazuju da se relativna važnost projektnih parametara koji utječu na potrebnu energiju za grijanje, potrebnu energiju za hlađenje te na emisije CO₂ razlikovala. Međutim, u svim analiziranim slučajevima među pet najutjecajnijih parametara dosljedno su se nalazili stopa infiltracije zraka, orijentacija, širina prozora, koeficijent prolaska Sunčeve topline, koeficijent prolaska topline prozora (U-vrijednost) i debljina toplinsko-izolacijskog materijala.

Tablica 2. Razina utjecaja projektnih parametara (AIR, WW-S, SHGC-S, WW-E, IT-W) na potrebnu energiju za grijanje i hlađenje te na emisije CO₂

	Četiri pročelja		Tri pročelja					
	A1	A9	A2	A10	A3	A11	A4	A12
Potrebna energija								
Grijanje	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)
	(WW-S)	(WW-S)	(WW-S)	(WW-S)	(WW-S)	(WW-S)	(WW-E)	(Uw-N)
	(SHGC-S)	(Uw-N)	(ORI)	(ORI)	(ORI)	(ORI)	(WW-W)	(WW-E)
	(WW-E)	(SHGC-S)	(SHGC-S)	(Uw-N)	(SHGC-S)	(Uw-N)	(SHGC-E)	(SHGC-E)
	(IT-W)	(WW-E)	(WW-W)	(SHGC-S)	(WW-E)	(SHGC-S)	(SHGC-W)	(SHGC-W)
Hlađenje	(WW-E)	(WW-E)	(WW-S)	(WW-S)	(WW-E)	(WW-E)	(WW-E)	(WW-E)
	(WW-S)	(SHGC-N)	(WW-N)	(SHGC-N)	(WW-S)	(SHGC-E)	(WW-W)	(ORI)
	(SHGC-E)	(WW-S)	(AIR)	(WW-W)	(SHGC-E)	(WW-S)	(WW-N)	(SHGC-N)
	(AIR)	(SHGC-E)	(SHGC-S)	(AIR)	(WW-N)	(SHGC-N)	(SHGC-E)	(SHGC-E)
	(WW-W)	(AIR)	(WW-W)	(SHGC-S)	(SHGC-S)	(AIR)	(AIR)	(WW-W)
Emisija CO ₂	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)
	(WW-E)	(WW-E)	(WW-N)	(ORI)	(ORI)	(WW-E)	(WW-N)	(Uw-N)
	(WW-N)	(SHGC-N)	(WH-N)	(Uw-W)	(WW-E)	(SHGC-N)	(WW-E)	(ORI)
	(SEA-S)	(WW-W)	(ORI)	(SEA-N)	(WW-N)	(SHGC-E)	(IT-E)	(WW-E)
	(IT-W)	(SHGC-E)	(IT-W)	(Uw-N)	(IT-N)	(ORI)	(SEA-W)	(IT-E)

Tablica 2. Razina utjecaja projektnih parametara (AIR, WW-S, SHGC-S, WW-E, IT-W) na potrebnu energiju za grijanje i hlađenje te na emisije CO₂- nastavak

Potrebna energija	Dva pročelja						Jedno pročelje	
	A5	A13	A6	A14	A7	A15	A8	A16
								
Grijanje	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)
	(ORI)	(ORI)	(ORI)	(ORI)	(WW-S)	(WW-S)	(Uw-N)	(Uw-N)
	(WW-E)	(Uw-N)	(WW-E)	(WW-E)	(SHGC-S)	(Uw-N)	(IT-N)	(SHGC-N)
	(Uw-N)	(SHGC-N)	(SHGC-E)	(Uw-N)	(WH-S)	(SHGC-S)	(SHGC-N)	(IT-N)
	(Uw-W)	(WW-W)	(IT-N)	(SHGC-N)	(Uw-S)	(Uw-S)	(WW-N)	(ORI)
Hlađenje	(WW-N)	(SHGC-N)	(WW-E)	(WW-E)	(WW-S)	(SHGC-N)	(WW-N)	(SHGC-N)
	(WW-W)	(WW-W)	(WW-N)	(ORI)	(WW-N)	(WW-S)	(AIR)	(ORI)
	(AIR)	(ORI)	(ORI)	(SHGC-N)	(SHGC-S)	(AIR)	(SHGC-N)	(Uw-N)
	(SHGC-N)	(AIR)	(SHGC-E)	(SHGC-E)	(AIR)	(SHGC-S)	(ORI)	(AIR)
	(SHGC-W)	(Uw-N)	(AIR)	(AIR)	(SHGC-N)	(WH-S)	(WH-N)	(SEA-N)
Emisija CO ₂	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)	(AIR)
	(ORI)	(ORI)	(ORI)	(ORI)	(WW-N)	(SHGC-N)	(IT-N)	(Uw-N)
	(Uw-N)	(Uw-N)	(WW-N)	(Uw-N)	(WW-S)	(Uw-N)	(WW-N)	(ORI)
	(Uw-W)	(Uw-W)	(WW-E)	(Uw-E)	(Uw-S)	(WH-S)	(Uw-N)	(SEA-N)
	(WW-N)	(IT-W)	(IT-N)	(WW-E)	(WH-N)	(SEA-S)	(ORI)	(ISHV-N)

2.3. Primjena metode optimizacije

Metodom optimizacije određuju se projektni parametri koji će se primjenjivati pri optimizaciji, definiraju funkcije cilja, provodi optimizacijski postupak te pronalaze optimalna rješenja za projektne varijante modela zgrade s obzirom na projektne parametre pročelja (rezultati optimizacije). Parametri upotrijebljeni pri optimizaciji određeni su dodatnom razradom projektnih parametara definiranih u početnoj fazi analize osjetljivosti na temelju njezinih rezultata. Rezultati analize osjetljivosti pokazali su da se redoslijed važnosti projektnih parametara koji utječu na potrebnu energiju za grijanje, potrebnu energiju za hlađenje te na emisije CO₂ razlikovao među modelima. Međutim, stopa infiltracije zraka i orijentacija utjecale su na cijelu zgradu, dok su koeficijent prolaska Sunčeve topline kroz prozor (SHGC), širina prozora, koeficijent prolaska topline prozora (U-vrijednost) i debljina toplinsko-izolacijskog materijala zida vrednovani za svako pročelje te su se dosljedno nalazili među pet najutjecajnijih parametara (tablica 2.). U fazi optimizacije znatni parametri utvrđeni analizom osjetljivosti dodatno su specificirani uvođenjem raznih vrsta materijala i slojeva, osobito u kategorijama prozora i zidova, kako bi se omogućilo vrednovanje raznih materijalnih varijanti. Osim toga, parametar stope infiltracije zraka, koji se u analizi osjetljivosti

kretao u rasponu od 0,1 do 1,2, zbog svoje dominantne uloge u rezultatima analize osjetljivosti fiksiran je na vrijednost 0,5 i uključen u postupak optimizacije.

Posebno su koeficijent solarnog dobitka topline (SHGC) i U-vrijednost prozora (UW), identificirani tijekom analize osjetljivosti, kombinirani kako bi se formirao parametar vrste stakla (GT) za optimizaciju (tablica 3.). Slično tome, parametri vrste izolacijskog materijala (IMT) u optimizaciji stvoreni su integracijom debljine izolacijskog materijala zida (IT), toplinske vodljivosti (ICV) i vrijednosti specifične topline (ISHV) iz kategorije zidova (tablica 4.). Dok se analizom osjetljivosti procjenjivao neovisni učinak svakog parametra (ukupno 38 parametara), u fazi optimizacije analizirane su kombinirane materijalne alternative, uz smanjenje broja parametara na 25. U tablici 3. navedeni su parametri vrste stakla korištene u optimizaciji, a u tablica 4. parametri vrste izolacijskog materijala [45]. Parametri vrste stakla i vrste izolacijskog materijala određeni su na temelju građevnih materijala koji se često upotrebljavaju u građevinskoj industriji i turskog standarda TS 825<5/> [35]. Vrijednosti orijentacije, širine prozora, visine prozora, dubine zasjenjivača, kuta zasjenjivača, stope infiltracije zraka te vrijednosti materijala definirane u parametrima vrste stakla i vrste izolacijskog materijala analizirane su u fazi optimizacije. U tablici 5. navedeni su nazivi projektnih parametara, pročelja na koja utječu i njihove kratice.

Tablica 3. Vrijednosti parametra za različite vrste stakla

Broj	Vrsta stakla	Slojevi	Površina	Ispuna	Vrijednost SHGC	UW
1	Nepremazano	4+16+4	Obično staklo	16 mm argon	0,78	2,6
2		4+12+4+12+4	Obično staklo	12 mm zrak	0,71	1,9
3		4+16+4+16+4	Obično staklo	16 mm argon	0,71	1,7
4	Staklo s premazom za kontrolu prolaska topline	4+12+4	Niskoemisijsko staklo	12 mm zrak	0,55	1,6
5		4+16+4	Niskoemisijsko staklo	16 mm argon	0,55	1,1
6		4+12+4+12+4	Niskoemisijsko staklo	12 mm zrak	0,48	0,9
7		4+16+4+16+4	Niskoemisijsko staklo	16 mm argon	0,48	0,6
8	Staklo s premazom za kontrolu prolaska topline i sunčeva zračenja	4+12+4	Solarno niskoemisijsko staklo	12 mm zraka	0,44	1,6
9		4+16+4	Solarno niskoemisijsko staklo	16 mm argon	0,44	1,1
10		4+12+4+12+4	Solarno niskoemisijsko staklo	12 mm zraka	0,4	0,9
11		4+16+4+16+4	Solarno niskoemisijsko staklo	16 mm argon	0,4	0,6

Tablica 4. Vrijednosti parametra različitih vrsta toplisko-izolacijskih materijala

Broj	Vrsta izolacijskog materijala	Debljina [mm]	Vrijednost toplinske vodljivosti [W/m K]	Vrijednost specifične topline [J/kg K]
1	Kamena vuna	50	0,037	840
2		60	0,037	840
3		80	0,037	840
4		100	0,037	840
5	Ekspandirana polistirenska pjena (EPS)	50	0,039	1500
6		60	0,039	1500
7		70	0,039	1500
8		80	0,039	1500
9		100	0,039	1500
10		120	0,039	1500
11	Ekstrudirana polistirenska pjena (XPS)	50	0,035	1500
12		60	0,035	1500
13		70	0,035	1500
14		80	0,035	1500
15		100	0,035	1500
16		120	0,035	1500

Nakon što su određeni projektni parametri koji će se primjenjivati u optimizaciji, potrebno je definirati ciljeve projekta i kriterije energetske učinkovitosti zgrade koji će se unaprijediti pri formuliranju funkcije cilja. U ovome istraživanju potrebna energija za grijanje, potrebna energija za hlađenje i vrijednosti emisija CO₂ definirani su kao tri cilja koja je potrebno istodobno minimizirati u sklopu problema optimizacije s više ciljeva. Za istodobnu optimizaciju tih funkcija upotrijebljen je program *jEPlus+EA*. Emisije CO₂ izračunane su primjenom izraza koji se temelji na godišnjim vrijednostima potrebne energije za grijanje i potrebne energije za hlađenje dobivenima programom *jEPlus+EA*. Ukupne godišnje emisije CO₂ izračunane su množenjem potrebne energije za grijanje i potrebne energije

za hlađenje koeficijentom konverzije emisija CO₂ od 0,234 za energiju dobivenu iz prirodnog plina i 0,418 za električnu energiju, pri čemu su ti koeficijenti povezani s vrstom goriva koja se koristi u Turskoj [33, 11].

Nakon što su određeni projektni parametri koji će se primjenjivati u optimizaciji i nakon što je definirana funkcija cilja, proveden je optimizacijski postupak. Za optimizaciju primijenjen je algoritam NSGA-II unutar programa *jEPlus+EA*, pri čemu su definirane postavke veličine populacije, stope križanja, stope mutacije i broja generacija. Algoritam NSGA-II integriran u program *jEPlus+EA* omogućuje učinkovit pristup i pruža okvir za optimizaciju arhitektonskog projektiranja. Preporučeni raspon vrijednosti za veličinu populacije iznosi od 10 do 200, za stopu

Tablica 5. Definiranje parametara koji će se upotrebljavati pri optimizaciji

Projektni parametar	Pročelje	Kratica	Jedinica	Raspon vrijednosti
Orijentacija		(ORI)	stupanj	0, 45, 315
Širina prozora	Sjeverno pročelje	(WW-N)	m	1,5 – 8,5
	Južno pročelje	(WW-S)	m	1,5 – 8,5
	Istočno pročelje	(WW-E)	m	1,5 – 8,5
	Zapadno pročelje	(WW-W)	m	1,5 – 8,5
Visina prozora	Sjeverno pročelje	(WH-N)	m	1,5 – 2,5
	Južno pročelje	(WH-S)	m	1,5 – 2,5
	Istočno pročelje	(WH-E)	m	1,5 – 2,5
	Zapadno pročelje	(WH-W)	m	1,5 – 2,5
Vrsta stakla (SHGC)–(UW–W/m ² K)	Sjeverno pročelje	(GT-N)	-	-
	Južno pročelje	(GT-S)	-	-
	Istočno pročelje	(GT-E)	-	-
	Zapadno pročelje	(GT-W)	-	-
Vrsta izolacijskog materijala (IT–m)–(ISHV–J/kg–K)–(ICV–W/m K)	Sjeverno pročelje	(IMT-N)	-	-
	Južno pročelje	(IMT-S)	-	-
	Istočno pročelje	(IMT-E)	-	-
	Zapadno pročelje	(IMT-W)	-	-
Dubina elementa za zasjenjivanje	Sjeverno pročelje	(SED-N)	m	0,1 – 0,2
	Južno pročelje	(SED-S)	m	0,1 – 0,2
	Istočno pročelje	(SED-E)	m	0,1 – 0,2
	Zapadno pročelje	(SED-W)	m	0,1–0,2
Kut elementa za zasjenjivanje	Sjeverno pročelje	(SEA-N)	stupanj	10 – 90
	Južno pročelje	(SEA-S)	stupanj	10 – 90
	Istočno pročelje	(SEA-E)	stupanj	10 – 90
	Zapadno pročelje	(SEA-W)	stupanj	10 – 90

križanja od 0,4 do 0,99, za stopu mutacije od 0,0001 do 0,1, dok maksimalni broj generacija treba biti manji od 1000 [46, 47]. U ovome istraživanju veličina populacije postavljena je na 20, stopa križanja na 0,9, a stopa mutacije na 0,1 kako bi se postigla optimalna ravnoteža između vremena proračuna i pouzdanosti dobivenih rješenja. Optimizacijski postupak završen je nakon što su, u skladu s definiranom funkcijom cilja i primijenjenim algoritmom, dobivena optimalna rješenja. Šesnaest modela razvijenih u ovome istraživanju rezultiralo je skupovima rješenja kojima su minimizirani potrebna energija za grijanje, potrebna energija za hlađenje i emisije CO₂ zgrade.

3. Rezultati

Rezultati optimizacije analizirani su na temelju potrebne energije za grijanje i potrebne energije za hlađenje (kWh), vrijednosti emisija CO₂ (kg) te vrijednosti projektnih parametara pročelja modela. Na temelju dobivenih rezultata rasponi vrijednosti

dobiveni Pareto-optimalnim rješenjima pokazali su znatne razlike u potrebnoj energiji za grijanje, potrebnoj energiji za hlađenje i emisijama CO₂.

Za konfiguracije s četiri pročelja (A1 i A9), model A1 imao je godišnju potrebnu energiju za grijanje u rasponu od 211 do 2080, dok se godišnja potrebna energija za hlađenje kretala između 1071 i 8510, a godišnje emisije CO₂ između 292 i 1019. Model A9 imao je godišnju potrebnu energiju za grijanje u rasponu od 222 do 2401, godišnja potrebna energija za hlađenje kretala se između 1645 i 9136, a godišnje emisije CO₂ između 367 i 1094. Za konfiguracije s trima otvorenim pročeljima rasponi ostvarenih vrijednosti razlikovali su se ovisno o tome koje je pročelje bilo neprozirno. Kada je istočno pročelje bilo neprozirno (A2 i A10), tada je model A2 ostvario toplinsko opterećenje za grijanje u rasponu od 214 do 2172, toplinsko opterećenje za hlađenje između 749 i 7018 te emisije CO₂ između 240 i 1048. Model A10 imao je toplinsko opterećenje za grijanje u rasponu od 230 do 2242, toplinsko opterećenje za hlađenje između 1173 i 7601 te

emisije CO₂ između 311 i 1075. Za konfiguraciju s neprozirnim zapadnim pročeljem (A3 i A11) model A3 imao je toplinsko opterećenje za grijanje u rasponu od 168 do 2396, toplinsko opterećenje za hlađenje između 1026 i 9290 te emisije CO₂ između 265 i 1102. Model A11 imao je toplinsko opterećenje za grijanje u rasponu od 210 do 2273, toplinsko opterećenje za hlađenje između 1458 i 9361 te emisije CO₂ između 338 i 1146. Kada je južno pročelje bilo neprozirno (A4 i A12), tada je model A4 imao toplinsko opterećenje za grijanje u rasponu od 275 do 2259, toplinsko opterećenje za hlađenje između 968 i 9245 te emisije CO₂ između 387 i 1095. Model A12 imao je toplinsko opterećenje za grijanje u rasponu od 250 do 2458, toplinsko opterećenje za hlađenje između 1396 i 9337 te emisije CO₂ između 424 i 1183.

Za konfiguracije s dvama otvorenim pročeljima, odnosno s neprozirnim istočnim i južnim pročeljem (A5 i A13), model A5 ostvario je toplinsko opterećenje za grijanje u rasponu od 380 do 2322, toplinsko opterećenje za hlađenje između 699 i 5456 te emisije CO₂ između 302 i 1053. Model A13 ostvario je toplinsko opterećenje za grijanje u rasponu od 417 do 2422, toplinsko opterećenje za hlađenje između 1113 i 6095 te emisije CO₂ između 376 i 1107. Za konfiguraciju s neprozirnim zapadnim i južnim pročeljem (A6 i A14) model A6 ostvario je toplinsko opterećenje za grijanje u rasponu od 194 do 2298, toplinsko opterećenje za hlađenje između 866 i 9147 te emisije CO₂ između 359 i 1116. Model A14 ostvario je toplinsko opterećenje za grijanje u rasponu od 210 do 2648, toplinsko opterećenje za hlađenje između 1293 i 9781 te emisije CO₂ između 539 i 1190. Slično tome, za konfiguraciju s neprozirnim istočnim i zapadnim pročeljem (A7 i A15), model A7 ostvario je toplinsko opterećenje za grijanje u rasponu od 174 do 2067, toplinsko opterećenje za hlađenje između 686 i 6652 te emisije CO₂ između 215 i 930. Model A15 ostvario je toplinsko opterećenje za grijanje u rasponu od 185 do 2083, toplinsko opterećenje za hlađenje između 1240 i 6801 te emisije CO₂ između 301 i 1001.

Za konfiguraciju s jednim otvorenim pročeljem, pri kojoj su istočno, zapadno i južno pročelje bili neprozirni (A8 i A16), model A8 ostvario je toplinsko opterećenje za grijanje u rasponu od 1137 do 2257, toplinsko opterećenje za hlađenje između 651 i 5646 te emisije CO₂ između 504 i 937. Model A16 ostvario je toplinsko opterećenje za grijanje u rasponu od 1152 do 2280, toplinsko opterećenje za hlađenje između 1095 i 5950 te emisije CO₂ između 510 i 1014.

Osim usporedbe modela u parovima, cjelovita analiza svih 16 modela (A1 – A16) pruža širi uvid u energetske ponašanje zgrada s pročeljima različitih konfiguracija. S povećanjem broja neprozirnih pročelja uočen je jasan trend porasta ukupnoga energetske opterećenja. Modeli sa samo jednim neprozirnim pročeljem (A2 – A10, A3 – A11, A4 – A12) ostvarili su najuravnoteženije energetske značajke jer su toplinski dobici od Sunčeva zračenja ostali dostatni, dok su toplinska opterećenja za hlađenje ostala u prihvatljivim granicama. Modeli s dvama neprozirnim pročeljima (A5 – A13, A6 – A14, A7 – A15) pokazali su veća toplinska opterećenja za grijanje, ovisno o orijentaciji.

Modeli s trima neprozirnim pročeljima (A8 – A16), čiji su otvori bili smješteni samo na sjevernome pročelju, ostvarili su veća toplinska opterećenja za grijanje zbog smanjene izloženosti Sunčevu zračenju, dok je difuzna dnevna svjetlost tijekom ljeta također pridonijela povećanju toplinskog opterećenja za hlađenje. Slijedom toga, emisije CO₂ pokazale su sličan obrazac. Razlike u orijentaciji pročelja također su imale važnu ulogu u energetske bilanci zgrade. Kada je istočno pročelje bilo neprozirno (A2 – A10), izostali su jutarnji Sunčevi dobici, što je dovelo do blagog povećanja potrebne energije za grijanje. Nasuprot tome, kada je zapadno pročelje bilo neprozirno (A3 – A11), tada je učinkovito smanjeno djelovanje poslijepodnevnoga Sunčeva zračenja, čime su smanjene potrebe za energijom za hlađenje i poboljšana ukupna energetska učinkovitost. Potpuno zatvaranje južnog pročelja (A4 – A12) uzrokovalo je najveće povećanje potrebne energije za grijanje zbog izostanka Sunčevih dobitaka tijekom zimskog razdoblja. Projektne varijante s neprozirnim istočnim i zapadnim pročeljima (A7 – A15) smanjile su dnevnu asimetriju Sunčeva zračenja, što je rezultiralo najnižim emisijama CO₂ unutar te skupine modela. Usporedbom parova modela različitih omjera prozirnosti sjevernog pročelja može se uočiti da povećanje omjera prozirnosti sjevernog pročelja u pravilu dovodi do povećanja potrebne energije za grijanje i emisija CO₂, dok je njegov utjecaj na potrebnu energiju za hlađenje manje izražen i ovisi o konfiguraciji pročelja. Također, sa smanjenjem broja otvorenih pročelja utjecaj projektnih parametara postaje izraženiji, a osjetljivost energetske učinkovitosti na promjene omjera prozirnosti raste. Dobiveni rezultati potvrđuju da je pri optimiranju projektnih rješenja potrebno istodobno uzeti u obzir omjer prozirnosti, broj otvorenih pročelja i njihovu orijentaciju kako bi se postigla uravnotežena i energetske učinkovita projektna rješenja.

Zatim je analiza proširena ispitivanjem vrijednosti parametara i odgovarajućih rezultata za slučajeve u kojima su ostvarene minimalne vrijednosti pokazatelja učinkovitosti (tablica 6.), pri čemu je naglasak stavljen na konfiguracije parametara povezane s minimalnim vrijednostima unutar analiziranih raspona. U tablici 6. prikazane su vrijednosti projektnih parametara odabrane iz Pareto-optimalnog skupa koje odgovaraju minimalnome godišnjem toplinskom opterećenju za grijanje, minimalnome godišnjem toplinskom opterećenju za hlađenje ili minimalnim godišnjim emisijama CO₂ za svaki par funkcionalno povezanih modela. Rješenje se smatralo Pareto-optimalnim ako nije bilo moguće smanjiti vrijednost jednog cilja bez istodobnog pogoršanja najmanje jednog drugog cilja. U tablici 6. modeli zgrada (A1 – A16) raspoređeni su u istome retku prema broju otvorenih pročelja i omjeru prozirnosti sjevernog pročelja. Tako su modeli s otvorima na četirima pročeljima grupirani kao A1 – A9, modeli s otvorima na trima pročeljima kao A2 – A10, A3 – A11 i A4 – A12, modeli s otvorima na dvama pročeljima kao A5 – A13, A6 – A14 i A7 – A15, a modeli s otvorima samo na jednome pročelju kao A8 – A16 [24]. Tablica sadržava po tri reprezentativna cjelovita rješenja odabrana iz Pareto dijagrama svakog modela. Svako rješenje obuhvaća međusobno usklađen

Tablica 6. Odabrana Pareto-optimalna rješenja za minimiziranje toplinskog opterećenja za grijanje, toplinskog opterećenja za hlađenje i emisija CO₂ [24]

	(ORI)	(WW-N)	(WW-S)	(WW-E)	(WW-W)	(WH-N)	(WH-S)	(WH-E)	(WH-W)	(GT-N)	(GT-S)	(GT-E)	(GT-W)	(IMT-N)	(IMT-S)	(IMT-E)	(IMT-W)	(SED-N)	(SED-S)	(SED-E)	(SED-W)	(SEA-N)	(SEA-S)	(SEA-E)	(SEA-W)	Grijanje [kWh]	Hlađenje [kWh]	CO ₂ [kg]
A1	315	1,5	7,5	1,5	8,5	1,70	2,30	1,5	2,50	10	3	7	7	16	11	10	10	0,14	0,1	0,16	0,1	10	10	20	20	211	5.725	590
	0	1,5	1,5	1,5	1,5	1,70	1,5	1,5	1,5	10	4	6	8	1	10	10												
	0	1,5	8,5	1,5	1,5	1,70	2,50	1,5	1,5	10	4	6	8	16	10	10	10	0,20	0,1	0,16	0,16	10	10	10	10	391	1.986	292
	0	-	8,5	1,5	3,5	-	2,50	1,60	1,90	11	3	11	7	15	16	16	15	0,20	0,1	0,16	0,14	10	10	30	10	222	3.743	409
A9	0	-	2,5	1,5	1,5	-	1,90	1,60	1,80	8	4	10	6	14	16	16	3	0,16	0,1	0,16	0,14	10	10	10	10	1,724	1,645	627
	0	-	8,5	1,5	1,5	-	1,70	1,60	1,90	11	3	11	7	15	16	16	15	0,20	0,1	0,16	0,14	10	10	10	10	324	2.990	367
	0	1,5	8,5	-	1,5	1,5	2,50	-	1,5	6	3	-	6	3	10	-	9	0,1	0,1	-	0,12	20	10	-	10	214	2.270	270
	0	1,5	1,5	-	1,5	1,5	2,30	-	1,5	6	8	-	9	5	14	-	2	0,1	0,20	-	0,12	20	10	-	10	1,940	749	604
A2	0	1,5	8,5	-	1,5	1,5	2,50	-	1,5	6	5	-	6	3	10	-	10	0,1	0,1	-	0,12	20	10	-	10	276	1.768	240
	315	-	7,5	-	8,5	-	2,40	-	1,70	11	7	-	11	3	10	-	10	0,12	0,16	-	0,14	10	10	-	10	230	4.324	465
	0	-	1,5	-	1,5	-	1,60	-	1,5	8	8	-	8	6	10	-	15	0,12	0,14	-	0,18	10	10	-	10	2.076	1,173	681
	0	-	8,5	-	1,5	-	2,10	-	1,60	11	7	-	11	3	16	-	9	0,12	0,16	-	0,1	10	10	-	10	324	2.389	311
A3	0	1,5	8,5	8,5	-	1,70	2,50	2,30	-	6	3	11	-	15	14	16	-	0,12	0,16	0,1	-	10	10	20	-	168	5.371	545
	0	1,5	1,5	1,5	-	1,5	1,5	1,5	-	11	10	11	-	1	14	16	-	0,16	0,16	0,1	-	80	10	20	-	1,733	1,026	573
	0	1,5	8,5	1,5	-	1,90	2,30	1,5	-	8	7	10	-	15	14	16	-	0,12	0,16	0,1	-	10	10	20	-	289	1.995	265
	0	-	8,5	1,5	-	-	2,40	1,5	-	11	3	10	-	9	15	15	-	0,20	0,20	0,16	-	10	10	20	-	210	3.387	372
A11	0	-	1,5	1,5	-	-	1,5	1,5	-	8	8	10	-	1	1	16	-	0,12	0,20	0,16	-	10	10	10	-	2.060	1,458	702
	0	-	8,5	1,5	-	-	2,30	1,5	-	10	7	10	-	3	4	16	-	0,1	0,12	0,16	-	10	10	10	-	326	2.679	339
	45	1,5	-	8,5	1,5	2,20	-	2,50	2,10	11	-	1	7	16	-	10	9	0,1	-	0,14	0,12	10	-	10	20	275	5.517	588
	315	1,5	-	1,5	1,5	1,60	-	1,80	1,80	11	-	10	8	16	-	10	10	0,16	-	0,16	0,12	10	-	10	10	1,815	968	590
A4	45	1,5	-	6,5	1,5	1,60	-	2,30	1,60	10	-	7	7	16	-	10	9	0,16	-	0,14	0,12	10	-	10	10	466	2.791	387
	45	-	-	8,5	1,5	-	-	2,40	1,5	11	-	3	10	16	-	16	4	0,20	-	0,1	0,18	10	-	10	10	250	6.657	687
	315	-	-	1,5	1,5	-	-	1,5	1,60	8	-	5	8	15	-	13	7	0,12	-	0,20	0,18	10	-	20	10	2,318	1,396	768
	315	-	-	1,5	8,5	-	-	1,5	2,50	11	-	11	7	12	-	16	14	0,18	-	0,14	0,18	10	-	10	10	564	2.893	424
A12																												

Tablica 6. Odabrana Pareto-optimalna rješenja za minimiziranje toplinskog opterećenja za grijanje, toplinskog opterećenja za hlađenje i emisija CO₂ [24] - nastavak

	(ORI)	(WW-N)	(WW-S)	(WW-E)	(WW-W)	(WH-N)	(WH-S)	(WH-E)	(WH-W)	(GT-N)	(GT-S)	(GT-E)	(GT-W)	(IMT-N)	(IMT-S)	(IMT-E)	(IMT-W)	(SED-N)	(SED-S)	(SED-E)	(SED-W)	(SEA-N)	(SEA-S)	(SEA-E)	(SEA-W)	Grijanje [kWh]	Hlađenje [kWh]	CO ₂ [kg]
 A5	315	1,5	-	-	8,5	2,30	-	-	2,50	7	-	-	3	16	-	-	16	0,16	-	-	0,16	10	-	-	10	380	2.596	346
	315	1,5	-	-	1,5	1,5	-	-	1,70	8	-	-	8	13	-	-	16	0,12	-	-	0,18	10	-	-	10	1.833	699	569
	315	1,5	-	-	8,5	1,60	-	-	2,50	10	-	-	7	16	-	-	16	0,12	-	-	0,18	10	-	-	10	460	1.891	302
 A13	315	-	-	-	8,5	-	-	-	2,50	7	-	-	7	12	-	-	16	0,16	-	-	0,18	10	-	-	10	417	2.963	390
	315	-	-	-	1,5	-	-	-	1,5	8	-	-	8	7	-	-	9	0,12	-	-	0,16	10	-	-	10	2.087	1113	678
	315	-	-	-	8,5	-	-	-	2,50	11	-	-	7	16	-	-	10	0,18	-	-	0,20	10	-	-	10	430	2770	376
 A6	45	1,5	-	8,5	-	1,80	-	2,50	-	10	-	3	-	16	-	3	-	0,18	-	0,20	-	30	-	10	-	194	5299	546
	315	1,5	-	1,5	-	1,5	-	1,60	-	10	-	11	-	3	-	16	-	0,12	-	0,16	-	10	-	10	-	1909	866	606
	45	1,5	-	8,5	-	1,5	-	1,70	-	11	-	11	-	16	-	16	-	0,20	-	0,20	-	10	-	10	-	485	2.432	359
 A14	45	-	-	8,5	-	-	-	2,50	-	7	-	7	-	8	-	15	-	0,14	-	0,12	-	10	-	20	-	210	6.341	647
	315	-	-	1,5	-	-	-	1,60	-	8	-	8	-	6	-	10	-	0,12	-	0,14	-	10	-	10	-	2.251	1.293	740
	45	-	-	8,5	-	-	-	1,5	-	11	-	11	-	16	-	15	-	0,1	-	0,14	-	10	-	10	-	491	4.350	539
 A7	0	1,5	8,5	-	-	1,70	2,40	-	-	7	3	-	-	4	15	-	-	0,18	0,14	-	-	20	10	-	-	174	2.271	259
	0	1,5	1,5	-	-	1,5	2,00	-	-	10	8	-	-	5	9	-	-	0,18	0,16	-	-	10	10	-	-	1732	686	541
	0	1,5	8,5	-	-	1,5	2,20	-	-	7	7	-	-	10	4	-	-	0,18	0,14	-	-	10	10	-	-	241	1606	215
 A15	0	-	8,5	-	-	-	2,40	-	-	11	3	-	-	15	12	-	-	0,12	0,14	-	-	10	10	-	-	185	3089	338
	0	-	1,5	-	-	-	1,60	-	-	8	5	-	-	11	13	-	-	0,1	0,12	-	-	10	10	-	-	1.879	1.240	632
	0	-	8,5	-	-	-	2,30	-	-	11	7	-	-	8	10	-	-	0,1	0,20	-	-	10	10	-	-	227	2.566	301
 A8	45	8,5	-	-	-	2,50	-	-	-	7	-	-	-	16	-	-	-	0,20	-	-	-	60	-	-	-	1137	4084	692
	0	1,5	-	-	-	1,5	-	-	-	8	-	-	-	2	-	-	-	0,1	-	-	-	10	-	-	-	1.914	651	587
	315	6,5	-	-	-	2,50	-	-	-	7	-	-	-	16	-	-	-	0,1	-	-	-	10	-	-	-	1.380	1.337	504
 A16	45	-	-	-	-	-	-	-	-	7	-	-	-	16	-	-	-	0,20	-	-	-	90	-	-	-	1.152	4.247	712
	315	-	-	-	-	-	-	-	-	8	-	-	-	5	-	-	-	0,14	-	-	-	10	-	-	-	2.068	1.095	671
	315	-	-	-	-	-	-	-	-	7	-	-	-	16	-	-	-	0,1	-	-	-	10	-	-	-	1.312	1.598	510

skup vrijednosti parametara koji pripada istome pojedinačnom rješenju, zajedno s odgovarajućim vrijednostima triju funkcija cilja: minimalnim godišnjim toplinskim opterećenjem za grijanje, minimalnim godišnjim toplinskim opterećenjem za hlađenje i minimalnim godišnjim emisijama CO₂. Usporedba modela A1 – A8 i A9 – A16 pokazuje da su pojedine vrijednosti parametara ostale jednake u različitim konfiguracijama, dok su se druge razlikovale ovisno o rasporedu pročelja i projektnim uvjetima. Dobiveni rezultati pokazuju da, kada je južno pročelje neprozirno, zgrada ostvaruje minimalne vrijednosti pri orijentacijama od 45° i 315°, dok su, kada je južno pročelje otvoreno, najpovoljniji rezultati ostvareni pri orijentaciji od 0°. U pogledu širine prozora, osim kod modela s jednim otvorenim sjevernim pročeljem, minimalne vrijednosti pokazatelja učinkovitosti uglavnom su postignute najmanjim vrijednostima širine prozora na sjevernome pročelju, na južnome, istočnome i zapadnome pročelju širine od približno 8,5 m rezultirale su minimalnim toplinskim opterećenjem za grijanje, a južnome, istočnome i zapadnome pročelju širine od približno 1,5 m minimalnim toplinskim opterećenjem za hlađenje. U pogledu visine pročelja uočeno je da su u rješenjima kojima je minimizirano toplinsko opterećenje za grijanje odabrane veće vrijednosti, dok su u rješenjima kojima je minimizirano toplinsko opterećenje za hlađenje odabrane manje vrijednosti za sjeverno, istočno i zapadno pročelje, pri čemu je sjeverno pročelje u pravilu imalo najmanje vrijednosti visine. Kada je riječ o vrsti ostakljenja, s povećanjem veličine sjevernog pročelja za minimiziranje toplinskog opterećenja za grijanje odabrano je ostakljenje s nižim U-vrijednostima, dok je za minimiziranje toplinskog opterećenja za hlađenje prednost dano ostakljenju s višim U-vrijednostima. Usporedba parova modela s različitim omjerima prozirnosti sjevernog pročelja upućuje na to da su promjene prozirnosti utjecale na odabir vrijednosti parametara povezanih s minimalnim vrijednostima pokazatelja učinkovitosti.

4. Zaključak

U ovom su istraživanju primjenom optimizacije s više ciljeva istodobno analizirane projektne varijante pročelja kako bi se utvrdio utjecaj parametara projektiranja pročelja na energetske učinkovitost zgrade. Analizirano je šesnaest modela stambenih zgrada (A1 – A16), razvrstanih prema orijentaciji pročelja i udjelu ostakljenja, radi smanjenja potreba za energijom za grijanje i hlađenje te emisija CO₂. Kao projektno ograničenje postupno je povećavan udio ostakljenja sjevernog pročelja, čime su simulirani stvarni arhitektonski uvjeti u kojima zgrade s kvalitetnim pogledom često imaju veće ostakljene površine na sjevernome pročelju. Kako bi se ispitao utjecaj toga neizbježnog projektnog zahtjeva na energetske učinkovitost zgrade, analizirani su modeli sa sjevernim pročeljem čiji je udio ostakljenja bio fiksiran na 80 % (A9 – A16). Postizanje minimalnih potreba za energijom za grijanje i hlađenje te što manjih emisija CO₂ zahtijeva primjenu sustava za potporu odlučivanju kojim se određuju optimalne kombinacije cjelovito vrednovanih projektnih parametara. Zato je optimizacija s više ciljeva učinkovit pristup za određivanje

optimalnih projektnih rješenja te pruža vrijednu potporu arhitektima, projektantima i donosiocima odluka u unaprijeđenju energetske svojstava zgrada. Glavni rezultati istraživanja mogu se sažeti kako slijedi:

- Analiza osjetljivosti uspostavlja okvir kojim se pojašnjava način na koji projektni parametri pročelja utječu na energetske učinkovitost zgrade. Rezultati su pokazali važnost pojedinih promjena vrijednosti parametara u modelima s velikim otvorima na sjevernome pročelju, čime se projektantima omogućuje donošenje utemeljenih odluka pri određivanju prioriteta projektnih parametara.
- U umjereno vlažnoj klimi Samsuna utvrđeno je da široka pročelja orijentirana prema sjeveru znatno utječu na energetske ponašanje zgrade, osobito zbog svojstava ostakljenja. Dobiveni rezultati potvrđuju da strategije projektiranja pročelja trebaju biti prilagođene specifičnome klimatskom kontekstu i potrebama korisnika te ističu osjetljivost energetske učinkovitosti pročelja na klimatske uvjete.
- Vrijednosti projektnih parametara, određene na temelju rezultata analize osjetljivosti, primijenjene su u postupku optimizacije, pri čemu su za svaki model dobivena optimalna rješenja s obzirom na toplinsko opterećenje za grijanje, toplinsko opterećenje za hlađenje i emisije CO₂. Rezultati pokazuju da odluke o projektiranju pročelja trebaju ovisiti o orijentaciji: otvori na južnome pročelju imaju ključnu ulogu u smanjenju toplinskog opterećenja za grijanje, dok ograničavanje otvora na istočnome i zapadnome pročelju doprinosi smanjenju toplinskog opterećenja za hlađenje i toplinskih dobitaka od Sunčeva zračenja. Kada je južno pročelje neprozirno, utvrđeno je da postizanje optimalnih vrijednosti zahtijeva ne samo promjene projektnih parametara pročelja, nego i promjenu orijentacije zgrade. U tome slučaju optimalna svojstva postignuta su pri orijentacijama od 45° i 315°. Kada je zgrada neprozirna na svim pročeljima osim južnoga, u pravilu se može orijentirati pod kutom od 0°.
- Sa smanjenjem broja otvora projektne odluke povezane s energetske učinkovitošću postaju osjetljivije, čime se dodatno naglašava ključna uloga optimizacije u cjelokupnome procesu projektiranja. U usporedbi s modelom koji ima otvorena sva četiri pročelja, model s otvorima samo na sjevernome pročelju pokazao je približno 419 % veće toplinsko opterećenje za grijanje, 33,4 % manje toplinsko opterećenje za hlađenje i 39 % veće emisije CO₂. Takva je konfiguracija najviše ograničena te zahtijeva precizno određivanje vrste ostakljenja i toplinsko-izolacijskog materijala kako bi se postigla uravnotežena energetska učinkovitost.
- Parametarska prilagodljivost otvorenosti pročelja, vrste ostakljenja i toplinsko-izolacijskog materijala pruža najveće mogućnosti za poboljšanje energetske učinkovitosti. Uključivanje otvora na sjevernome pročelju kao varijabilnoga projektnog parametra povećava mogućnost postizanja uravnoteženih projektnih rješenja, dok njegovo zadržavanje na nepromijenjenoj vrijednosti otežava postupak optimizacije i dodatno povećava utjecaj ostalih projektnih parametara.

Zato je optimizacija s više ciljeva ključna za postizanje uravnoteženih projektnih rješenja visoke energetske učinkovitosti. Ovo istraživanje potvrđuje važnu ulogu optimizacije u postizanju optimalnih projektnih rješenja čak i u uvjetima zadanih arhitektonskih ograničenja.

Analize u ovome istraživanju provedene su primjenom postojećih klimatskih podataka. S obzirom na promjene koje će donijeti globalno zatopljenje, bit će potrebno definirati nova optimalna projektna rješenja jer će se pristupi projektiranju i načini njihove primjene s vremenom mijenjati. Predviđa se da će se u Turskoj nakon tridesetih godina 20. stoljeća temperatura ubrzano povećavati [49]. Budući da će se to odraziti na energetske učinkovitost zgrada povećanjem toplinskog opterećenja za hlađenje i smanjenjem toplinskog opterećenja za grijanje, u budućim istraživanjima bit će važno uzeti u obzir mogućnost da će klimatske promjene produljiti razdoblje u kojemu je potrebno

hlađenje. Cilj budućih istraživanja jest proširiti primjenu razvijenog modela na različite klimatske zone, uz uključivanje budućih klimatskih scenarija i proračuna troškova, te razviti alate koji će služiti kao potpora projektantima, proizvođačima i donosiocima odluka. Razvoju održivoga izgrađenog okoliša može se pridonijeti projektiranjem i izgradnjom stambenih zgrada prilagodljivih promjenjivim klimatskim uvjetima te uključivanjem proračuna troškova u postupke projektiranja energetske učinkovitih stambenih zgrada za različite klimatske regije Turske.

Zahvala

Autori su se koristili alatom ChatGPT radi poboljšanja čitljivosti rukopisa. Nijedan alat temeljen na umjetnoj inteligenciji nije korišten za izradu znanstvenog sadržaja, analizu podataka niti donošenje zaključaka.

LITERATURA

- [1] Tucker, S., Bleil de Souza, C.: Thermal simulation outputs: exploring the concept of patterns in design decision-making, *Journal of Building Performance Simulation*, 9 (2016) 1, pp. 30–49.
- [2] Attia, S., Gratia, E., De Herde, A., Hensen, J.L.M.: Simulation-based decision support tool for early stages of zero-energy building design, *Energy and Buildings*, 49 (2002), pp. 2–15.
- [3] Hopfe, C.J., Hensen, J.L.M.: Uncertainty analysis in building performance simulation for design support, *Energy and Buildings*, 43 (2011) 10, pp. 2798–2805.
- [4] Saltelli, A., Tarantola, F., Campolongo, F., Ratto, M.: *Sensitivity Analysis in Practice: A Guide to Assessing Scientific Models*, John Wiley & Sons Ltd., Chichester, 2004.
- [5] Tian, W.: A review of sensitivity analysis methods in building energy analysis, *Renewable and Sustainable Energy Reviews*, 20 (2013), pp. 411–419.
- [6] Ulukavak Harputlugil, G.: *An Assessment Model Addressed to Early Phases of Architectural Design Process Prioritised by Energy Performance*, Ph.D. Thesis, Gazi University Institute of Science and Technology, Ankara, 2009.
- [7] Yıldız, Y., Korkmaz, K., Göksal Özbalt, T., Durmuş Arsan, Z.: An approach for developing sensitive design parameter guidelines to reduce the energy requirements of low-rise apartment buildings, *Applied Energy*, 93 (2012), pp. 337–347.
- [8] Gerçek, M., Arsan, Z.D.: Energy and environmental performance-based decision support process for early design stages of residential buildings under climate change, *Sustainable Cities and Society*, 48 (2019), Article No. 101580.
- [9] Nguyen, A.T.: *Sustainable Housing in Vietnam: Climate Responsive Design Strategies to Optimize Thermal Comfort*, Ph.D. Thesis, Liege University, Liege, Belgium, 2013.
- [10] Şenel Solmaz, A.: Optimisation of energy performance and thermal comfort of an office building, *GRAĐEVINAR*, 70 (2018) 7, pp. 581–592, <https://doi.org/10.14256/JCE.2136.2017>
- [11] Mangan, S.D.: Development of a web-based decision support tool for sustainable residential building design and retrofit, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (2021) 4, pp. 1785–1800, <https://doi.org/10.17341/gazimmfd.815489>
- [12] Gagne, J., Andersen, M.: Multi-objective façade optimization for daylighting design using a genetic algorithm, 4th National Conference of IBPSA-USA, New York, pp. 11–13, 2010.
- [13] Jin, Q.: *A whole-life value optimization model for façade design*, Ph.D. Thesis, University of Cambridge, Department of Engineering, England, 2013.
- [14] Kültür, S., Türkeri, N., Knaack, U.: A holistic decision support tool for façade design, *Buildings*, 9 (2019), Article No. 186.
- [15] Tokarik, M.S.: *A multi-objective optimization analysis of passive energy conservation measures in a Toronto house*, Ph.D. Thesis, Ryerson University, Ontario, Canada, 2011.
- [16] Zhang, Y., Korolija, I.: Performing complex parametric simulations with jEPlus, SET2010 – 9th International Conference on Sustainable Energy Technologies, Shanghai, China, pp. 24–27, 2010.
- [17] Kahsay, M.T., Bitsuamlak, G.T., Tariku, F.: Thermal zoning and window optimization framework for high-rise buildings, *Applied Energy*, 292 (2021), <https://doi.org/10.1016/j.apenergy.2021.116894>
- [18] Attia, S., O'Brien, W., Farrag, M.: Early design decision support tools for energy-efficient buildings, *Renewable and Sustainable Energy Reviews*, 16 (2012) 8, pp. 5612–5623.
- [19] Kolokotsa, D., Diakaki, C., Grigoroudis, E., Stavrakakis, G., Kalaitzakis, K.: Decision support methodologies on the energy efficiency and energy management in buildings, *Advances in Building Energy Research*, 3 (2009) 1, pp. 121–146, <https://doi.org/10.3763/aber.2009.0305>
- [20] Al-Anzi, F.S., Al-Dosary, H.A., Al-Harthy, A.F.: Evaluation of passive solar design strategies in buildings: The role of climatic conditions in the design process, *Energy*, 34 (2009) 7, pp. 1075–1082.

- [21] Nasrollahi, N.: Effects of urban and locational factors on energy consumption in buildings: A case study of energy performance in high-latitude climates, *Energy and Buildings*, 41 (2009) 11, pp. 1149–1158.
- [22] ASHRAE: ASHRAE Handbook—Fundamentals, American Society of Heating, Refrigerating and Air-Conditioning Engineers, Atlanta, 2021.
- [23] Hien, W.N., Yu, L., Lim, P.E.: Thermal performance of building façades in tropical climates, *Energy and Buildings*, 37 (2005) 5, pp. 478–486.
- [24] Gökşen, F., Ayçam, İ.: Thermal performance assessment of opaque ventilated façades for residential buildings in hot humid climates, *GRAĐEVINAR*, 75 (2023) 3, pp. 225–237, <https://doi.org/10.14256/JCE.3576.2022>
- [25] Autor: Naslov izostavljen radi postupka dvostruko slijepe recenzije, doktorska disertacija, naziv ustanove izostavljen, 2024.
- [26] Berköz, E., Küçükdoğan, M., Yılmaz, Z., Kocaaslan, G., Yıldız, E., Köknel, A., Ünver, R., Ak, F., Enarun, D., Yıldız, D.: Enerji etkin konut ve yerleşme tasarımı (TÜBİTAK-İNTAG 201), İstanbul Teknik Üniversitesi, İstanbul, 1995.
- [27] Altensis: DesignBuilder Software, www.altensis.com/hizmetler/designbuilder-software/, 19.08.2021.
- [28] Turski zavod za statistiku (TSI): Statistički podaci o obiteljima, data.tuik.gov.tr/Bulten/Index?p=Istatistiklerle-Aile-2021-45632, 11.10.2022.
- [29] ANSI/ASHRAE Standard 55–2010: Thermal environmental conditions for human occupancy, American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc., 2010, <http://arco-hvac.ir/wp-content/uploads/2015/11/ASHRAE-55-2010.pdf>, 09.08.2016.
- [30] Crawley, D.A., Lawrie, L.: Climate files, climate.onebuilding.org, 01.10.2021.
- [31] Turska državna meteorološka služba: Opći statistički podaci o pokrajinama, www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k=H&m=SAMSUN, 10.08.2021.
- [32] Metoda izračuna energetska učinkovitost zgrada: Službeni glasnik Republike Turske, br. 27778, Ankara, 2010.
- [33] Ministarstvo energetike i prirodnih izvora Republike Turske: Publikacije ministarstva, Ankara, 2019.
- [34] Turski zavod za statistiku (TSI): Odabrani pokazatelji, biruni.tuik.gov.tr/ilgosterge/?locale=tr, 05.10.2019.
- [35] Turski institut za norme: TS 825 Toplinska zaštita zgrada, Ankara, 2008.
- [36] Autor: Podaci o autoru izostavljeni radi postupka dvostruko slijepe recenzije, 2023.
- [37] Helton, J.C., Johnson, J.D., Sallaberry, C.J., Storlie, C.B.: Survey of sampling-based methods for uncertainty and sensitivity analysis, *Reliability Engineering & System Safety*, 91 (2006) 10, pp. 1175–1209.
- [38] Sallaberry, C.J., Helton, J.C., Hora, S.C.: Extension of Latin hypercube samples with correlated variables, *Reliability Engineering & System Safety*, 93 (2008) 7, pp. 1047–1059.
- [39] SimLab: SimLab version 2.2 reference manual, European Commission IPSC, <http://simlab.jrc.ec.europa.eu/>, 2008.
- [40] Zhang, Y., Jankovic, L.: JEA: An interactive optimization engine for building energy performance simulation, IBPSA Building Simulation 2017, San Francisco, USA, pp. 7–9, 2017.
- [41] Zhang, Y.: Use jEPlus as an efficient building design optimisation tool, CIBSE ASHRAE Technical Symposium, London, UK, 2012.
- [42] Zhang, Y.: 'Parallel' EnergyPlus and the development of a parametric analysis tool, IBPSA BS2009, Glasgow, UK, pp. 27–30, 2009.
- [43] Zhang, Y., Korolija, I.: Performing complex parametric simulations with jEPlus, SET2010 – 9th International Conference on Sustainable Energy Technologies, Shanghai, China, pp. 24–27, 2010.
- [44] Naboni, E., Maccarini, A., Korolija, I., Zhang, Y.: Comparison of conventional, parametric and evolutionary optimization approaches for the architectural design of nearly zero energy buildings, *Proceedings of BS2013, Chambery, France*, pp. 2559–2566, 2013.
- [45] Autor: Naslov izostavljen radi postupka dvostruko slijepe recenzije, konferencijski rad, pojednosti izostavljene, 2022.
- [46] Lei, Y.J., Zhang, S.W., Li, X.B., Zhou, C.M.: MATLAB genetic algorithm toolbox and application, Xidian University Press, 2005.
- [47] Li, T., Shao, G., Zuo, W., Huang, S.: Genetic algorithm for building optimization: State-of-the-art survey, *Proceedings of the 9th International Conference on Machine Learning and Computing*, pp. 205–210, 2017.
- [48] Abbass, H.A., Sarker, R., Newton, C.: PDE: A Pareto-frontier differential evolution approach for multi-objective optimization problems, *Proceedings of the 2001 Congress on Evolutionary Computation*, IEEE, pp. 971–978, 2001.
- [49] Mangan, S.D., Oral, G.K.: Evaluation of the effects of settlement patterns on building energy performance in the context of climate change, *3rd National Congress of Building Physics and Environmental Control Proceedings Book*, Istanbul, pp. 33–40, 2018.