

KLASA: 641-04/18-01/03
URBROJ: 2170-57-06-00-18-06

Naručitelj: AGENCIJA ZA DRUŠTVENO POTICANU
STANOGRADNJU GRADA RIJEKE
Titov trg 3, 51000 Rijeka

Izvršitelj: GRAĐEVINSKI FAKULTET U RIJECI
Radmile Matejčić 3, 51000 Rijeka

Građevina: POS građevine na Hostovom bregu, Drenovi i Rujevici

Lokacija: Grad Rijeka

ZNASTVENO ISTRAŽIVANJE - MATEMATIČKO MODELIRANJE PROSTORNOG PRONOSA VLAGE UNUTAR POSTOJEĆIH STAMBENIH JEDINICA USLIJED ŽIVOTNIH NAVIKA STANARA

Broj studije: 019/2018

Voditelj studije: doc. dr. sc. Ivan Marović

Dekanica:

Izv. prof. dr. sc. Ivana Štimac Grandić



Rijeka, rujan 2018.

Sadržaj

I DIO — ELABORAT O PROVEDENOM ISTRAŽIVANJU	3
Uvod	4
Područje istraživanja	5
Predmet i problematika znanstvenog istraživanja	5
Metodologija	6
Provedba mjerenja	8
Mjerenja temperature i vlage u promatranoj stambenoj jedinici	12
Mjerenja temperature i vlažnosti zraka na području grada Rijeke	18
Rezultati.....	21
Rezultati mjerenja provedenog unutar pozicije dnevni boravak	21
Rezultati mjerenja provedenog unutar pozicije kuhinja	24
Rezultati mjerenja provedenog unutar pozicije kupaoonica	28
Rezultati mjerenja provedenog unutar pozicije spavaća soba.....	32
Prijedlog mjera poboljšanja.....	35
Literatura	36
Prilozi.....	37
Prilog 1 – Rezultati mjerenja provedenog unutar stambene jedinice br. 17 – Hostov breg.....	37
Prilog 2 – Rezultati mjerenja provedenog unutar stambene jedinice br. 15 – Drenova.....	43
Prilog 3 – Rezultati mjerenja provedenog unutar stambene jedinice br. 5 – Drenova.....	49
Prilog 4 – Rezultati mjerenja provedenog unutar stambene jedinice br. 8 – Rujevica.....	55
Prilog 5 – Znanstveni rad prihvaćen za objavu na međunarodnom znanstvenom skupu PBE 2018	61
II DIO — NUMERIČKA SIMULACIJA PROSTORNOG ŠIRENJA VLAGE UNUTAR POSTOJEĆIH STAMBENIH JEDINICA USLIJED ŽIVOTNIH NAVIKA STANARA	68
Uvod	69
Problematica novogradnji – usporedba sa starijom gradnjom.....	70
Odabir parametara simulacije	71
Eksperimentalno istraživanje	71
Promatrani događaji.....	71
Numerički model	73
Simulacija događaja.....	75
Tok simulacije	76

Početno stanje ($t = 0$ s).....	76
Drugi dio – faza zagrijavanja ($t=0$ do 10 min).....	76
Treći dio – faza intenzivnog kuhanja	77
Četvrti dio – faza hlađenja.....	78
Analiza dobivenih rezultata	79
Analiza temperatura.....	79
Analiza vlage	80
Konačna analiza i prijedlog rješenja	87
Zaključak.....	88

I DIO

Elaborat o provedenom istraživanju

Uvod

Ova elaborat izrađen je na temelju Ugovora o javnim uslugama broj: UG-0222-A od 19.03.2018. godine za Znanstveno istraživanje – Matematičko modeliranje prostornog pronosa vlage unutar postojećih stambenih jedinica uslijed životnih navika stanara sklopljenog između Agencije za društveno poticanu stanogradnju Grada Rijeke (u daljnjem tekstu Naručitelj) i Građevinskog fakulteta u Rijeci (u daljnjem tekstu Izvršitelj).

Istraživanjem je bilo potrebno napraviti:

- Po dogovoru sa Naručiteljem izabrati 4 karakteristične nekretnine (stana) iz portfelja nekretnina Naručitelja koje su građene po programu poticajne stanogradnje,
- Na izabranim nekretninama utvrditi pozicije i postaviti mjerne instrumente. U svakoj izabranoj nekretnini (stambenoj jedinici) potrebno je postaviti minimalno 5 mjernih instrumenata za temperaturu i vlagu,
- Mjernim instrumentima je potrebno kontinuirano prikupljati podatke u trajanju od minimalno 42 dana (period snimanja),
- Tijekom perioda snimanja potrebno je prikupiti minutne podatke o temperaturi i relativnoj vlažnosti svake izabrane nekretnine u neprekinutom vremenskom nizu stoga je nužno svakih 7 dana napraviti vizualni pregled nekretnina i prikupiti podatke s mjernih instrumenata,
- Prikupiti hidrometeorološke podatke s lokalne hidrometeorološke postaje za ukupno vrijeme prikupljanja podataka,
- Na temelju prikupljenih podataka od 4 karakteristične nekretnine potrebno odabrati jednu nekretninu odnosno karakteristični događaj zabilježen mjeracima temperature i vlage te temeljem toga izraditi matematičku simulaciju (tzv. HVAC CFD analizu),
- Na temelju prikupljenih podataka potrebno je izraditi elaborat za odabrane karakterističnu nekretnine.

Na temelju navedenog izrađen je ovaj elaborat koji sadrži metodologiju prikupljanja i prikupljene podatke sa svih mjernih pozicija smještenih unutar prethodno odabranih nekretnina u svom tiskanom i digitalnom obliku. Svi prikupljeni podaci sa mjernih instrumenata i podaci koji su korišteni u izradi ovog elaborata nalaze se na pripadajućem DVD-u.

Cjelokupan elaborat se sastoji od dva dijela. Prvi dio elaborata sadrži podatke o provedenim mjerenjima temperature i vlage, vanjske temperature, analizu distribucije vlage te prijedloge mjera poboljšanja uslijed visoke vlažnosti u prostoru promatranih stambenih jedinica, dok je u drugom dijelu elaborata prikazana numerička simulacija prostornog širenja vlage zabilježenog karakterističnog događaja unutar jedne stambene jedinice nastalog uslijed životnih navika stanara.

Područje istraživanja

Predmet i problematika znanstvenog istraživanja

Svjedoci smo stalnog porasta populacije u urbanim područjima koje sa sobom povlači brojne posljedice. Pritom se očekuje da će do 2030. godine 60% ukupnog broja svjetskog stanovništva, a čak 84% stanovništva razvijenih zemalja, živjeti u urbanim područjima [1]. Ovakvi podaci na svjetskoj razini su vrlo alarmantni jer sa sobom otvaraju brojne probleme života u urbanim sredinama. Problem kontinuiranog i obilnog povećanja broja stanovništva u gradovima često se rješava neplaniranim pa čak i stihijskim gradnjama stambenih prostora što direktno utječe na naglo povećanje gustoće stanovništva u pojedinim gradskim zonama povećanjem stambenog sustava kojeg adekvatno ne prate ostali infrastrukturni sustavi [2]. Navedeno definitivno utječe na stambeni sustav, ali i na ostale sustave koji oblikuju urbano područje, na npr. cestovni sustav, sustavi vodoopskrbe i odvodnje, gospodarenja otpadom, itd., i kvalitetu života u njemu.

Stambeni prostori u urbanim područjima se redovito promatraju kroz prizmu okruženja pri čemu se vrednovanje stambenog okruženja u smislu utvrđivanja kvalitete života promatra pomoću različitih indikatora koji se načelno mogu grupirati u skupinu društvenih, ekonomskih, ekoloških i tehničkih indikatora [2, 3]. Brojni istraživači stambeno okruženje promatraju kroz unutrašnje i vanjske značajke. Pritom unutrašnje značajke su uglavnom tehničkog karaktera [4, 5, 6, 7] dok se vanjske značajke mogu definirati u različite skupine poput navedenih. Tako su Bakar i dr. [8, 9] vanjske značajke podijelili u šest osnovnih skupina pri čemu su promatrali okoliš, društvo, ekonomiju, korištenje zemljišta te komunikacijske i prometne aspekte sa stajališta održivog razvoja stambenog područja. Svakako, ukoliko se promatra kvaliteta života u stambenom prostoru tada na kvalitetu života utječu među ostalima ugrađeni materijali i tlocrtna dispozicija, ali i navike stanara. Pritom, brojna istraživanja točkasto promatraju pojedini materijal ili element konstrukcije sa svim svojim svojstvima ili objekt u cjelini, ali nijedno ne uzima u obzir da različitosti u navikama stanara istog stambenog prostora mogu imati različite utjecaje na higrotermalne (vlažnost i temperatura) vrijednosti stambene jedinice.

Stanari svoj životom u stanu svojim navikama generiraju određenu dodatnu količinu temperature i vlage uz postojeće razine uslijed grijanja i hlađenja prostora. Naročito se to očituje u prostorima kuhinje (kuhanje) i kupaonice (higijena tijela i robe) koji su glavni generatori vlage u stanu koja se kroz hodnike ili direktno pronosi u ostale dijelove stana (dnevni boravak, sobe, i dr.) te se nakuplja na hladnijim dijelovima zidova, stropova i ostalog. Generički se smatra da je idealna količina vlage u stambenom prostoru iznosi oko 45% dok se sve ispod 30% smatra previše suhim, a iznad 50% previše vlažnim, no stanari u svojim prostorima rijetko imaju neki uređaj putem kojeg bi se to razina vlage kontinuirano pratila i održavala u optimalnoj količini za obitavanje.

Stoga, izazovi stanovanja u stambenim prostorima, naročito novoizgrađenim i/ili novouređenim stambenim prostorima nameću nova pitanja i poglede na iste kao i nove načine ponašanja stanara za koje postoji malo podataka. Upravo ovim istraživanjem pokušat će se dati odgovor na pitanje da li i koliko navike stanara utječu na kvalitetu života u stambenom prostoru u pogledu temperature i vlage matematičkim modeliranjem pronosa vlage unutar postojećih stambenih jedinica te dati smjernice za poboljšanje istih.

Metodologija


Za potrebe ovog znanstvenog istraživanja razvijena je metodologija utvrđivanja pronosa vlage unutar postojećih stambenih jedinica uslijed životnih navika stanara koja je prikazana na slici 1 i objašnjena unutar ovog poglavlja.

Prvi korak je analiza nekretnina koje se nalaze unutar portfelja nekretnina te rezultira odabirom karakteristične nekretnine unutar koje/kojih će se postaviti instrumenti. Ovaj početni proces se preporuča napraviti u dogovoru s odgovornim osobama koji upravljaju portfeljem nekretnina, u ovom istraživanju Naručiteljem predmetnog zadatka, iz razloga što su oni najbolje upoznati sa nekretninama kao i njihovim životnim vijekom (od ideje do realizacije) kao i tijekom života stanara u istima. Nakon što se odaberu karakteristične nekretnine počinje detaljna analiza odabranih nekretnina koja obuhvaća razgovore sa svim dionicima (Naručitelj i stanari) te pregled tehničke dokumentacije kao i same nekretnine na lokaciji. Svaku odabranu nekretninu potrebno je pažljivo pregledati i utvrditi pozicije gdje će se postaviti mjerni instrumenti na način da podaci, koji će se tijekom perioda snimanja prikupljati, što preciznije prikažu stvarni utjecaj predmetnog istraživanja.

Nekretnine je potrebno vizualno pregledati izvana i iznutra, a same pozicije gdje će se postaviti mjerni uređaji (tzv. datalogeri) je potrebno utvrditi na način da se eliminira utjecaj temperature zida na rezultate mjerenja tijekom ugradnje mjerača temperature i vlage. U svakoj izabranoj nekretnini (stambenoj jedinici) potrebno je postaviti minimalno pet mjernih instrumenata da se što preciznije može utvrditi utjecaj pronosa vlage unutar postojećih stambenih jedinica uslijed životnih navika stanara. U tu svrhu je potrebno kontinuirano prikupljati podatke tijekom perioda snimanja. Također, važno je poznavati vanjske hidrometeorološke utjecaje što se može prikupiti s lokalnih hidrometeorološki postaja.

Slijedeći korak je analiza prikupljenih podataka. S obzirom da se radi o mjernim instrumentima koji prikupljaju podatke o temperaturi, vlazi i točki rosišta u pojedinom vremenskom intervalu (2 sek, 5 sek, 10 sek, 30 sek, 1 min, ...) radi se o velikoj količini prikupljenih podataka koje treba primjereno organizirati i obraditi. Također, preporuča se tjedni vizualni pregled tijekom kojeg se podaci s datalogera preuzimaju što doprinosi konzistenciji praćenja i evidentiranja prikupljenih podataka.

Nakon što se sirovi podaci prikupe potrebno ih je prije daljnje analize pripremiti. Na temelju provedene analize prikupljenih podataka mogu se donijeti zaključci o nekom karakterističnom događaju koji je zabilježen mjernim instrumentima i na temelju toga izraditi matematičku simulaciju. Navedena matematička simulacija će pokazati prostornu distribuciju vlage odnosno temperature unutar stambene jedinice čime bi se potvrdili rezultati mjerenja. Temeljem provedenog modeliranja prostornog pronosa vlage unutar promatrane nekretnine moguće je donijeti zaključke i smjernice za postupanje stanara kako bi se spriječilo nakupljanje (kondenziranje) vlage u rubnim, često najhladnijim, dijelovima stambenih jedinica tj. stana.



Slika 1: Metodologija utvrđivanja pronosa vlage unutar postojećih stambenih jedinica uslijed životnih navika stanara

Provedba mjerenja

Početni proces prethodno opisane metodologije je napravljen dogovoru sa Naručiteljem gdje je pritom odabrano četiri karakteristične nekretnine (stambene jedinice tj. stana) iz portfelja nekretnina Naručitelja koje su građene po programu poticajne stanogradnje. U samo istraživanje su uključeni vlasnici stanova na tri lokacije:

- POS Hostov breg I. faza
 - Stan broj 17
 - Stan broj 5
- POS Drenova
 - Stan broj 15
- POS Rujevica II. Faza
 - Stan broj 8


Nakon provedenih razgovora s Naručiteljem i stanarima navedenih stambenih jedinica (u daljnjem tekstu će se na stambene referirati putem njihovog broja 17, 5, 15, odnosno 8) pristupljeno je detaljnoj analizi stambenih jedinica. Kako bi se eliminirao utjecaj temperature zida na rezultate mjerenja tijekom ugradnje mjerača temperature i vlage izvršeno je snimanje termalnom kamerom. Prvenstveno je to napravljeno iz razloga kako bi se eliminirao utjecaj pozadinske topline zida ili elementa na koji će biti privremeno postavljeni mjerni instrumenti. Nakon perioda snimanja svi mjerni instrumenti su uklonjeni.

U svakoj stambenoj jedinici postavljeno je pet mjernih instrumenata. Njihov razmještaj je prikazan na slici 2 za stan broj 17, na slici 3 za stan broj 5, na slici 4 za stan broj 15 odnosno na slici 5 za stan broj 8. U digitalnom prilogu na DVD-u (mapa APOS fotografije) su priložene fotografije svih postavljenih mjernih instrumenata na svojim pozicijama unutar odabranih stambenih jedinica.


Mjerni instrumenti su postavljeni na prethodno utvrđene pozicije te je u tablici 1 prikazan njihov imenovani prostor unutar pojedine stambene jedinice.

Tablica 1: Sumarna tablica pozicija svih datalogera u promatranim stambenim jedinicama


Pozicija unutar stana	Stan broj 17	Stan broj 5	Stan broj 15	Stan broj 8
Dnevni boravak	-	HD5	D2	R1
Kuhinja	HB1	HD4	D3	R4
Kupaonica	HB2	HD1	D1	R2
WC	HB3	-	-	R3
Spavaća soba – 1	HB4	HD3	D5	R5
Spavaća soba – 2	HB5	HD2	-	-
Hodnik	-	-	D4	-




Slika 2: Razmještaj mjernih instrumenata unutar stambene jedinice br. 17



Slika 3: Razmještaj mjernih instrumenata unutar stambene jedinice br. 5



Slika 4: Razmještaj mjernih instrumenata unutar stambene jedinice br. 15



Slika 5: Razmještaj mjernih instrumenata unutar stambene jedinice br. 8

Mjerni instrumenti su odabrani na način da svojom veličinom ne smetaju normalnom životu ukućana stoga je za prikupljanje podataka korišten je mjerni instrument za kontinuirano mjerenje vlažnosti i temperature (engl. *datalogger*) model RHT10 proizvođača Extech Instruments. Ovaj mjerni uređaj je odabran zbog svojih karakteristika vezanih za mogućnost očitavanja te svojih malih dimenzija.

Na slici 6 prikazan je dataloger s pripadajućim stalkom. Unutar odabranih stambenih jedinica postavljeno je u svakoj po pet prikazanih instrumenata te su se prikupljali podaci o temperaturi, vlazi i točki rosišta u intervalima od 1 minute.



Slika 6: Datalogeri na svojim stalcima

Za pripremu mjernih uređaja kao i za očitavanje prikupljenih podataka korišten je softver RHT10-SW, dok se daljnja obrada prikupljenih podataka obavljala pomoću softvera MS Excel.

Mjerenja temperature i vlage u promatranoj stambenoj jedinici


Mjerenja su provedena tijekom ožujka i travnja 2018. godine u neprekinutom kontinuitetu od 42 dana odnosno 6 tjedana. Pritom je prikupljeno oko 60.000 podataka po jednom mjernom instrumentu, odnosno nešto više od 300.000 podataka unutar jedne stambene jedinice. Ukupno je prikupljeno 1.225.098 podataka za temperaturu, kao i za podatke o vlazi i točkama rosišta što znači da je ukupno prikupljeno 3.675.294 podataka koji su bili analizirani. Upravo zbog velike količine podataka u elaboratu će se prikazati samo jedan tjedni niz podataka mjernih instrumenata smještenih na poziciji dnevnog boravka svih stambenih jedinica.

Svi prikupljeni podaci su priloženi na DVD-u (mapa APOS mjerenja), kao i njihova obrada. Svaka stambena jedinica je obrađena (mapa PPodaci) zasebno te se obrada prikupljenih podataka u stanu broj 17 nalazi u datoteci imena *Podaci HB.xls*, obrada prikupljenih podataka u stanu broj 5 nalazi u datoteci imena *Podaci HD.xls*, obrada prikupljenih podataka u stanu broj 15 nalazi u datoteci imena *Podaci D.xls* te obrada prikupljenih podataka u stanu broj 8 nalazi u datoteci imena *Podaci R.xls*.


U nastavku su prikazani prikupljeni podaci na pozicijama na kojima se stvara najveća količina vlage u nekom kućanstvu, a to je kuhinja i kupaonica. Može se reći da su u modernom kućanstvu upravo to dva najveća potencijalna izvora vlage te da se mogu promatrati kao izvori za pronos vlage unutar stambenog prostora i promatrati kao direktna posljedica postupanja stanara.

Podaci s mjernih instrumenata prikupljeni tijekom 6. tjedna prikupljanja podataka na poziciji dnevnog boravka (za kod datalogera vidi tablicu 1) u stanu broj 17 (slika 7), u stanu broj 5 (slika 8), u stanu broj 15 (slika 9) i u stanu broj 8 (slika 10).


U prilogu 1 prikazani su podaci mjerenja prikupljeni tijekom cjelokupnog perioda mjerenja na poziciji kuhinje kod svih stambenih jedinica unutar jednog promatranog tjedna. Preostali podaci nalaze se u ranije predstavljenim datotekama unutar mape PPodaci.




Slika 7: Podaci prikupljeni na datalogeru HB1 tijekom 6. tjedna prikupljanja podataka



Slika 8: Podaci prikupljeni na datalogeru HD4 tijekom 6. tjedna prikupljanja podataka




Slika 9: Podaci prikupljeni na datalogeru D3 tijekom 6. tjedna prikupljanja podataka




Slika 10: Podaci prikupljeni na datalogeru R4 tijekom 6. tjedna prikupljanja podataka

Iz grafova prikazanih na slikama 7-10 moguće je uočiti različite životne navike stanara i fluktuaciju temperature prostora uslijed dinamike kuhanja te odziv točke rosišta, a naročito vlage unutar prostora. Ono što se može uočiti jest da u stambenim jedinicama koje imaju kuhinju smještenu uz vanjski zid koji ima prozor imaju nižu zasićenost prostora vlagom (slike 7 i 8) nego što je to kod prostora koji imaju kuhinju smještenu u centralnom dijelu stambenog prostora (slike 9 i 10).


Također, u nastavku su prikazani podaci mjerenja prikupljeni tijekom 4. tjedna prikupljanja podataka na poziciji kupaoonice (za kod datalogera vidi tablicu 1) u stanu broj 17 (slika 11), u stanu broj 5 (slika 12), u stanu broj 15 (slika 13) i u stanu broj 8 (slika 14).




Slika 11: Podaci prikupljeni na datalogeru HB2 tijekom 4. tjedna prikupljanja podataka



Slika 12: Podaci prikupljeni na datalogeru HD1 tijekom 4. tjedna prikupljanja podataka



Slika 13: Podaci prikupljeni na datalogeru D1 tijekom 4. tjedna prikupljanja podataka



Slika 14: Podaci prikupljeni na datalogeru R2 tijekom 4. tjedna prikupljanja podataka

Iz grafova prikazanih na slikama 11-14 moguće je uočiti različite životne navike stanara i fluktuaciju vlage unutar prostora kupaonice uslijed dinamike života te odziv točke rosišta i temperature tog prostora. Ono što se može uočiti jest izraženija fluktuacija i količina vlage u odnosu na kuhinjski prostor te da se vlaga dulje zadržava u ovom prostoru. Navedeno se može objasniti kroz nepostojanje prozora u kupaonicama kao i smještanju perilica za rublje koje uz svakodnevno obavljanje higijene ukućana značajno doprinosi stvaranju i održavanju visoke razine vlage samog prostora.

S obzirom da se radi stambenim jedinicama koje su promatrane u istom vremenskom periodu, istim instrumentima i na isti način može se pretpostaviti da je utjecaj vanjskih vremenskih uvjeta jednako utjecao na mjerne rezultate svih mjernih mjesta. Stoga, relativne razlike između mjernih instrumenata i prikupljenih podataka tijekom perioda mjerenja mogu se promatrati kao navike stanara dotične stambene jedinice. Time se prikupljeni podaci u stambenim jedinicama promatraju kao nezavisni od vanjskih utjecaja koji su prikupljeni i obrađeni u narednom poglavlju.

Mjerenja temperature i vlažnosti zraka na području grada Rijeke

Prikupljeni su hidrometeorološke podatke s lokalne hidrometeorološke postaje smještene na zgradi Građevinskog fakulteta za ukupno vrijeme perioda snimanja na odabranim nekretninama. Podaci su prikupljeni pomoću automatske meteorološke postaje Vantage Pro 2 (Davis Instruments Corporation) koja je nabavljena u sklopu projekta „Razvoj istraživačke infrastrukture na kampusu Sveučilišta u Rijeci“ (RC.2.2.06-0001).

Podaci su prikupljeni u 5-minutnom intervalu tijekom cjelokupnog perioda snimanja. Statistička obrada prikupljenih podataka za mjesec ožujak je prikazana u tablici 2, a za mjesec travanj u tablici 3. Prikupljeni podaci prikazani su digitalno u datoteci *Statistička analiza 3_4_2018_Kampus meteo dana.xls*.

Tablica 2: Statistička obrada prikupljenih meteoroloških podataka za mjesec ožujak 2018. godine

Statistički parametri*	Temperatura zraka	Maksimalna temperatura zraka	Minimalna temperatura zraka	Vlaga zraka	Temperatura točke rosišta	Brzina vjetra	Maksimalna brzina vjetra	Osjećaj hladnoće (vjetar)	Indeks topline	Tlak zraka	Količina oborine	Intenzitet oborina
	T	T	T	u	T	v	v	T	T	p	P	i
	[°C]	[°C]	[°C]	[%]	[°C]	[m/s]	[m/s]	[°C]	[°C]	[mmHg]	[mm]	[mm/h]
n	8854	8843	8843	8853	8843	8870	8870	8843	8843	8870	8870	8870
Max.	20,6	20,7	20,4	97	12,9	17,9	37,1	20,6	19,4	1021,3	1,4	111,8
Min.	-4	-4	-4,1	22	-15,1	0	0	-6,6	-4,4	991,8	0	0
$\bar{x}$	8,0	8,1	8,0	74,6	3,3	1,0	3,4	7,4	7,8	1006,0	0,0	0,2
σ	4,1	4,1	4,0	19,8	5,7	2,3	5,2	4,9	4,0	6,5	0,1	1,8


* n = Broj mjerenih podataka; Max. = maksimum; Min. = minimum; $\bar{x}$ = srednja vrijednost; σ = standardna devijacija.

Tablica 3: Statistička obrada prikupljenih meteoroloških podataka za mjesec travanj 2018. godine

Statistički parametri*	Temperatura zraka	Maksimalna temperatura zraka	Minimalna temperatura zraka	Vlaga zraka	Temperatura točke rosišta	Brzina vjetra	Maksimalna brzina vjetra	Osjećaj hladnoće (vjetar)	Indeks topline	Tlak zraka	Količina oborine	Intenzitet oborina
	T	T	T	u	T	v	v	T	T	p	P	i
	[°C]	[°C]	[°C]	[%]	[°C]	[m/s]	[m/s]	[°C]	[°C]	[mmHg]	[mm]	[mm/h]
n	8639	8639	8639	8639	8639	8639	8639	8639	8639	8639	8639	8639
Max.	32,3	32,4	32,3	97	16	8,5	19,2	32,3	31,3	771,1	0,8	18,8
Min.	7,3	7,3	7,2	18	-1,1	0	0	7,3	7,4	747,1	0	0
$\bar{x}$	17,6	17,7	17,6	58,9	8,3	0,3	1,9	17,6	17,1	761,3	0,0	0,1
σ	6,0	6,0	6,0	21,7	2,9	1,0	2,8	6,0	5,7	3,9	0,0	0,8


* n = Broj mjerenih podataka; Max. = maksimum; Min. = minimum; $\bar{x}$ = srednja vrijednost; σ = standardna devijacija.

Temperatura zraka se tijekom ožujka 2018. godine kretala od $T_{\min}=-4^{\circ}\text{C}$ do $T_{\max}=20,6^{\circ}\text{C}$. Mjerenja temperature zraka prikazana su na slici 15.




Slika 15: Prikaz mjerenja temperature zraka u petominutnom koraku za mjesec ožujak 2018. godine

Vlažnost zraka se tijekom ožujka 2018. godine kretala od $u_{\min}=22\%$ do $u_{\max}=97\%$. Mjerenja vlažnosti zraka prikazana su na slici 16.




Slika 16: Prikaz mjerenja vlažnosti zraka u petominutnom koraku za mjesec ožujak 2018. godine

Temperatura zraka se tijekom travnja 2018. godine kretala od $T_{\min}=7,3^{\circ}\text{C}$ do $T_{\max}=32,3^{\circ}\text{C}$. Mjerenja temperature zraka prikazana su na slici 17.



Slika 17: Prikaz mjerenja temperature zraka u petominutnom koraku za mjesec travanj 2018. godine

Vlažnost zraka se tijekom travnja 2018. godine kretala od $u_{\min}=18\%$ do $u_{\max}=97\%$. Mjerenja vlažnosti zraka prikazana su na slici 18.




Slika 18: Prikaz mjerenja vlažnosti zraka u petominutnom koraku za mjesec travanj 2018. godine

Rezultati

U ovom poglavlju prikazani su rezultati provedene analize. Rezultati su prikazani i diskutirani za svaku stambenu jedinicu, a grupirani su sukladno prethodno definiranim pozicijama (dnevni boravak, kuhinja, kupaonica i spavaća soba) unutar promatranih stambenih jedinica. Zbog velike količine podataka u elaboratu su prikazana mjerenja tijekom cijelog perioda snimanja, dok se preostali prikazi po tjednima nalaze na DVD-u u mapi PPodaci.xls. Statistička obrada na koju se u ovom poglavlju poziva je prikazana u Prilogu 1-4 ovog elaborata te se nalazi na DVD-u u mapi Ppodaci.xls.

Rezultati mjerenja provedenog unutar pozicije dnevni boravak

Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije dnevni boravak u stanu broj 5 prikazan je na slici 19. To je jedini mjerač u stanu broj 5 koji je imao prekid tijekom perioda prikupljanja podataka i to na samom početku mjerenja. Do prekida je došlo zbog pada mjernog instrumenta uzrokovan slučajnim udarcem stanara. Prekid je ustanovljen prilikom prvom prikupljanja podataka te je od tog trenutka mjerni instrument imao neprekinuti niz rada.




Slika 19: Prikaz mjerenja u stanu broj 5 tijekom cijelog perioda snimanja (pozicija dnevni boravak)

Statistička obrada podataka ovog mjernog instrumenta je prikazana u Prilogu 2. Zabilježen je tjedni medijan vlažnosti prostora koji varira od tjedna do tjedna od minimalnog 33,5% do maksimalnog 54,8%. Pritom je vidljivo (slika 19) brzi prirast i sporo rasterećenje prostora od vlage. Temperatura prostora dnevno fluktuira i preko 5 °C tijekom cijelog perioda snimanja te je izražena i fluktuacija točke rosišta prostora. Navedeno ukazuje da se u ovom prostoru tijekom cijelog dana odvijaju aktivnosti, a kako je prostor otvoren prema blagovaonici i kuhinji postoji direktni utjecaj i tamošnjih aktivnosti. To se temelji na brzim prirastima temperature i vlage (npr. aktivnost peglanje) te indirektno širenje iz kuhinje (aktivnost kuhanje).

Zbog svoje dinamike, na temelju podataka od ovog prostora je provedena numerička simulacija prostornog širenja vlage unutar postojećih stambenih jedinica uslijed životnih navika stanara koja se nalazi u dijelu II ovog elaborata.


Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije dnevni boravak u stanu broj 15 prikazan je na slici 20.



Slika 20: Prikaz mjerenja u stanu broj 15 tijekom cijelog perioda snimanja (pozicija dnevni boravak)

Statistička obrada podataka ovog mjernog instrumenta je prikazana u Prilogu 3. Zabilježen je tjedni medijan vlažnosti prostora koji varira od tjedna do tjedna od minimalnog 43,3% do maksimalnog 58,8%. Pritom je vidljivo (slika 20) brzi prirast i sporo rasterećenje prostora od vlage. Tijekom dana je veća razina vlage u prostoru dok se rasterećenje odvija tijekom noći. To je naročito izraženo na kraju 2. tjedna perioda snimanja kada je vrlo vjerojatno prozor ostao cijelu noć otvoren (mjerni instrument se nalazio na ormariću neposredno uz prozor tijekom cijelog perioda snimanja). Temperatura prostora dnevno fluktuira do 5 °C tijekom cijelog perioda snimanja kao i točke rosišta ovog prostora. Iz slike 20 može se razabrati konzistentan i harmoničan način življenja bez veći promjena. Navedeno ukazuje da se u ovom prostoru tijekom cijelog dana odvijaju aktivnosti, a kako je prostor otvoren prema blagovaonici i kuhinji postoji direktni utjecaj i tamošnjih aktivnosti.

Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije dnevni boravak u stanu broj 8 prikazan je na slici 21. To je jedini mjerač u stanu broj 8 koji je imao prekid tijekom perioda prikupljanja podataka i to na samom početku mjerenja. Do prekida je došlo zbog pada mjernog instrumenta uzrokovan slučajnim udarcem stanara. Prekid je ustanovljen prilikom prvom prikupljanja podataka te je od tog trenutka mjerni instrument imao neprekinuti niz rada.




Slika 21: Prikaz mjerenja u stanu broj 8 tijekom cijelog perioda snimanja (pozicija dnevni boravak)

Statistička obrada podataka ovog mjernog instrumenta je prikazana u Prilogu 4. Zabilježen je tjedni medijan vlažnosti prostora koji varira od tjedna do tjedna od minimalnog 50,0% do maksimalnog 63,7%. Pritom je vidljivo (slika 21) brzi prirast i sporo rasterećenje prostora od vlage. Temperatura prostora dnevno fluktuira do 5 °C tijekom cijelog perioda snimanja te je izražena i fluktuacija točke rosišta prostora. Navedeno ukazuje da se u ovom prostoru tijekom cijelog dana odvijaju aktivnosti, a kako je prostor otvoren prema kuhinji postoji direktni utjecaj i tamošnjih aktivnosti. To se temelji na brzim prirastima temperature i vlage te indirektno širenje iz kuhinje (aktivnost kuhanje).

Rezultati mjerenja provedenog unutar pozicije kuhinja


Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije kuhinja u stanu broj 17 prikazan je na slici 22.



Slika 22: Prikaz mjerenja u stanu broj 17 tijekom cijelog perioda snimanja (pozicija kuhinja)

Statistička obrada podataka ovog mjernog instrumenta je prikazana u Prilogu 1. Zabilježen je tjedni medijan vlažnosti prostora koji varira od tjedna do tjedna od minimalnog 45,4% do maksimalnog 54,3%. Pritom je vidljivo (slika 22) brzi prirast, ali i brzo rasterećenje prostora od vlage. Temperatura prostora dnevno fluktuirala do 7 °C tijekom cijelog perioda snimanja te je izražena i fluktuacija točke rosišta prostora. Navedeno ukazuje da se u ovom prostoru tijekom periodično odvijaju aktivnosti, a kako je prostor otvoren prema blagovaonici i dnevnom boravku te postoji direktni utjecaj i tamošnjih aktivnosti. Iako se radi o prostoru koji je uobičajeno najveći generator vlage u ovom slučaju podaci u kazuju na prihvatljivu razinu vlažnosti (iznimno je u nekim tjednima blago povišena) uz svakodnevna rasterećenja prostora od više vlažnosti.

Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije kuhinja u stanu broj 5 prikazan je na slici 23.




Slika 23: Prikaz mjerenja u stanu broj 5 tijekom cijelog perioda snimanja (pozicija kuhinja)

Statistička obrada podataka ovog mjernog instrumenta je prikazana u Prilogu 2. Zabilježen je tjedni medijan vlažnosti prostora koji varira od tjedna do tjedna od minimalnog 34,2% do maksimalnog 55,3%. Pritom je vidljivo (slika 23) brzi prirast i sporo rasterećenje prostora od vlage. Temperatura prostora dnevno fluktuira do 9 °C tijekom cijelog perioda snimanja te je izražena i fluktuacija točke rosišta prostora. Navedeno ukazuje da se u ovom prostoru tijekom cijelog dana odvijaju aktivnosti, a kako je prostor otvoren prema blagovaonici i dnevnom boravku postoji direktni utjecaj i tamošnjih aktivnosti. No kako se radi o prostoru koji je najveći generator vlage u ovoj stambenoj jedinici može se reći da je ostale prostorije predstavljaju rasterećenje ovog izvora. To se temelji na brzim prirastima temperature i vlage u kuhinji (aktivnost kuhanje) i širenje na ostale prostorije. Sve navedeno ukazuje da treba naći novo rješenje za uklanjanje viška vlage iz ovog prostora.

Zbog svoje dinamike, na temelju podataka od ovog prostora je provedeno numerička simulacija prostornog širenja vlage unutar postojećih stambenih jedinica uslijed životnih navika stanara koja se nalazi u dijelu II ovog elaborata.


Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije kuhinja u stanu broj 15 prikazan je na slici 24.



Slika 24: Prikaz mjerenja u stanu broj 15 tijekom cijelog perioda snimanja (pozicija kuhinja)

Statistička obrada podataka ovog mjernog instrumenta je prikazana u Prilogu 3. Zabilježen je tjedni medijan vlažnosti prostora koji varira od tjedna do tjedna od minimalnog 43,3% do maksimalnog 58,8%. Tijekom dana je veća razina vlage u prostoru dok se rasterećenje odvija tijekom noći. To je naročito izraženo na kraju 2. tjedna perioda snimanja kada je vrlo vjerojatno prozor ostao cijelu noć otvoren (mjerni instrument se nalazio na ormariću neposredno uz prozor tijekom cijelog perioda snimanja). Temperatura prostora dnevno fluktuirala do 5 °C tijekom cijelog perioda snimanja kao i točke rosišta ovog prostora. Navedeno ukazuje da se u ovom prostoru tijekom cijelog dana odvijaju aktivnosti, a kako je prostor otvoren prema blagovaonici i dnevnom boravku postoji direktni utjecaj i tamošnjih aktivnosti. No kako se radi o prostoru koji je najveći generator vlage u ovoj stambenoj jedinici i čini s blagavaonicom i dnevnom boravkom jedinstveni prostor treba ih promatrati zajedno. To se temelji na brzim prirastima temperature i vlage u kuhinji (aktivnost kuhanje) i širenje na ostale prostorije. Sve navedeno ukazuje da treba naći novo rješenje za uklanjanje viška vlage iz ovog prostora.

Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije kuhinja u stanu broj 8 prikazan je na slici 25.




Slika 25: Prikaz mjerenja u stanu broj 8 tijekom cijelog perioda snimanja (pozicija kuhinja)

Statistička obrada podataka ovog mjernog instrumenta je prikazana u Prilogu 4. Zabilježen je tjedni medijan vlažnosti prostora koji varira od tjedna do tjedna od minimalnog 47,9% do maksimalnog 60,8%. Tijekom dana je veća razina vlage u prostoru dok se rasterećenje odvija tijekom noći. Temperatura prostora dnevno fluktuiira do 8,5 °C tijekom cijelog perioda snimanja kao i točke rosišta ovog prostora. Navedeno ukazuje da se u ovom prostoru tijekom cijelog dana odvijaju aktivnosti, a kako je prostor otvoren prema dnevnom boravku postoji direktni utjecaj i tamošnjih aktivnosti. No kako se radi o prostoru koji je najveći generator vlage u ovoj stambenoj jedinici i čini s dnevnim boravkom jedinstveni prostor treba ih promatrati zajedno. To se temelji na brzim prirastima temperature i vlage u kuhinji (aktivnost kuhanje) i širenje na ostale prostorije. Sve navedeno ukazuje da treba naći novo rješenje za uklanjanje viška vlage iz ovog prostora.

Rezultati mjerenja provedenog unutar pozicije kupaonica


Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije kupaonica u stanu broj 17 prikazan je na slici 26.



Slika 26: Prikaz mjerenja u stanu broj 17 tijekom cijelog perioda snimanja (pozicija kupaonica)

Statistička obrada podataka ovog mjernog instrumenta je prikazana u Prilogu 1. Zabilježen je tjedni medijan vlažnosti prostora koji varira od tjedna do tjedna od minimalnog 46,0% do maksimalnog 57,5%. Pritom je vidljivo (slika 26) brzi prirast i sporo rasterećenje prostora od vlage uz kontinuirano dostizanje visokih razina vlažnosti tijekom dana pa slijedom toga tjedna i čitavog perioda snimanja. Brzo zasićenje prostora vlagom (do maksimalne vrijednosti od 85,5%) ukazuje da je prostor kontinuirano visoko zasićen vlagom i da je kratkotrajna aktivnost stanara dovoljna da zasićenost vlagom naraste. Temperatura prostora dnevno fluktuira do 4°C tijekom cijelog perioda snimanja te je izražena i fluktuacija točke rosišta prostora. Sve navedeno ukazuje da treba naći novo rješenje za uklanjanje viška vlage iz ovog prostora.


Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije kupaonica u stanu broj 5 prikazan je na slici 27.



Slika 27: Prikaz mjerenja u stanu broj 5 tijekom cijelog perioda snimanja (pozicija kupaonica)

Statistička obrada podataka ovog mjernog instrumenta je prikazana u Prilogu 2. Zabilježen je tjedni medijan vlažnosti prostora koji varira od tjedna do tjedna od minimalnog 33,2% do maksimalnog 53,7%. Pritom je vidljivo (slika 27) brzi prirast i sporo rasterećenje prostora od vlage uz kontinuirano dostizanje visokih razina vlažnosti tijekom dana pa slijedom toga tjedna i čitavog perioda snimanja. Brzo zasićenje prostora vlagom (do maksimalne vrijednosti od 92,6%) ukazuje da je prostor kontinuirano visoko zasićen vlagom i da je kratkotrajna aktivnost stanara dovoljna da zasićenost vlagom naraste. Temperatura prostora dnevno fluktuira do 6 °C tijekom cijelog perioda snimanja te je izražena i fluktuacija točke rosišta prostora. Sve navedeno ukazuje da treba naći novo rješenje za uklanjanje viška vlage iz ovog prostora.


Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije kupaonica u stanu broj 15 prikazan je na slici 28.



Slika 28: Prikaz mjerenja u stanu broj 15 tijekom cijelog perioda snimanja (pozicija kupaonica)

Statistička obrada podataka ovog mjernog instrumenta je prikazana u Prilogu 3. Zabilježen je tjedni medijan vlažnosti prostora koji varira od tjedna do tjedna od minimalnog 46,6% do maksimalnog 58,7%. Pritom je vidljivo (slika 28) brzi prirast i sporo rasterećenje prostora od vlage uz kontinuirano dostizanje visokih razina vlažnosti tijekom dana pa slijedom toga tjedna i čitavog perioda snimanja. Brzo zasićenje prostora vlagom (do maksimalne vrijednosti od 92,9%) ukazuje da je prostor kontinuirano visoko zasićen vlagom i da je kratkotrajna aktivnost stanara dovoljna da zasićenost vlagom naraste. Temperatura prostora dnevno fluktuiira do 6 °C tijekom cijelog perioda snimanja te je izražena i fluktuacija točke rosišta prostora. Sve navedeno ukazuje da treba naći novo rješenje za uklanjanje viška vlage iz ovog prostora.

Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije kupaonica u stanu broj 8 prikazan je na slici 29.



Slika 29: Prikaz mjerenja u stanu broj 15 tijekom cijelog perioda snimanja (pozicija kupaonica)


Statistička obrada podataka ovog mjernog instrumenta je prikazana u Prilogu 4. Zabilježen je tjedni medijan vlažnosti prostora koji varira od tjedna do tjedna od minimalnog 54,8% do maksimalnog 64,8%. Pritom je vidljivo (slika 29) brzi prirast i sporo rasterećenje prostora od vlage uz kontinuirano dostizanje visokih razina vlažnosti tijekom dana pa slijedom toga tjedna i čitavog perioda snimanja. Brzo zasićenje prostora vlagom (do maksimalne vrijednosti od 94,5%) ukazuje da je prostor kontinuirano visoko zasićen vlagom i da je kratkotrajna aktivnost stanara dovoljna da zasićenost vlagom naraste. Temperatura prostora dnevno fluktuira do 6 °C tijekom cijelog perioda snimanja te je izražena i fluktuacija točke rosišta prostora. Sve navedeno ukazuje da treba naći novo rješenje za uklanjanje viška vlage iz ovog prostora.

Rezultati mjerenja provedenog unutar pozicije spavaća soba

Prikupljeni podaci unutar pozicije spavaća soba nisu detaljno analizirani i komentirani zbog nenarušavanja privatnosti stanara već su prikupljeni podaci samo grafički prikazani slikama 30-33. Općenito se može reći da je podaci sa svih postavljenih mjernih instrumenata u poziciji spavaća soba ukazuju na povišenu razinu vlažnosti uz kontinuiranu, ali jednoliko ritmičnu, fluktuaciju.


Kako se radi o temperaturno najkonstantnijim pozicijama unutar promatrnih stambenih jedinica, sa nižim temperaturama u odnosu na ostale prostorije, izgledno je da se dio vlage preostalih prostorija pronosi ovdje. Upravo pravilnim djelovanjem u prostorijama koji su najveći generatori vlage indirektno bi se smanjila akumulirana vlažnost unutar pozicije spavaća soba.

Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije spavaća soba u stanu broj 17 prikazan je na slici 30.




Slika 30: Prikaz mjerenja u stanu broj 5 tijekom cijelog perioda snimanja (pozicija spavaća soba - 1)

Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije spavaća soba u stanu broj 5 prikazan je na slici 31.




Slika 31: Prikaz mjerenja u stanu broj 5 tijekom cijelog perioda snimanja (pozicija spavaća soba - 1)

Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije spavaća soba u stanu broj 15 prikazan je na slici 32.



Slika 32: Prikaz mjerenja u stanu broj 15 tijekom cijelog perioda snimanja (pozicija spavaća soba - 1)

Grafički prikaz prikupljenih podataka tijekom mjerenja unutar pozicije spavaća soba u stanu broj 8 prikazan je na slici 33.



Slika 33: Prikaz mjerenja u stanu broj 8 tijekom cijelog perioda snimanja (pozicija spavaća soba - 1)

Prijedlog mjera poboljšanja

Analizom podataka prikupljenih tijekom 6 tjedana mjerenja provedenih na lokacijama POS Hostov breg I. faza (stan broj 17 i stan broj 5), POS Drenova (stan broj 15) i POS Rujevica II. Faza (stan broj 8) potvrđuju osnovnu postavku istraživanja da navike stanara značajno utječu na kvalitetu života u stambenom prostoru u pogledu temperature i vlage te matematičkim modeliranjem pronosa vlage unutar postojećih stambenih jedinica te dati smjernice za poboljšanje istih.

Generalno svi stanovi imaju povišenu razinu vlažnosti u nekim prostorijama naročito onim kod kojih su aktivnosti vezane za prostore kuhinje, dnevnog boravka i kupaonice. Istraživanjem se ukazalo da prostori dnevnog boravka imaju brže rasterećenje od vlage s obzirom da ti prostori imaju jedan ili više prozora putem kojih se odvija prozračivanje. Također stanovi kod kojih je kuhinja smještena uz rubni zid s prozorom ima slično odvijanje rasterećenja dok stanovi kod kojih je kuhinja centralno smještena (bez prozora) ima rasterećenje slično onom kao što je kod kupaonica. Ovim istraživanjem kupaonice su identificirane kao prostori s najveće generiranjem vlage te zbog svog položaja postojeći načini usisnim ventilatorom to nije moguće u potpunosti izvesti. Pritom stanari pribjegavaju držanjem otvorenih vrata kupaonica čime se vlaga prenosi u ostale prostorije. Time se samo vrši transfer vlage, a ne i uklanjanje vlage iz prostora stana. Sve navedeno ukazuje da treba naći novo rješenje za uklanjanje viška vlage iz ovog prostora.

Kao mjera poboljšanja, za prikladno i ekonomski prihvatljivo rješenje ovog problema, nameću se električni odvlaživači zraka (engl. dehumidifier). Navedeni uređaji unutarnji zrak prostora drže na prihvatljivim razinama te se mogu integrirati u postojeće stanove u vidu fiksnih ili pak pomičnih odvlaživača. Pritom je dovoljno uvesti jedan pomični odvlaživač u promatrane prostore koji bi svojim kontinuiranim radom držao razinu vlage u zraku u razinama komfora. Iako ovi uređaji predstavljaju jedan dodatni uređaj o kojemu treba brinuti njegovo korištenje će zasigurno otvoriti nove mogućnosti, razine komfora i zdravlja svih ukućana.

Sastavio:

Doc. dr. sc. Ivan Marović, dipl. ing. građ.

Literatura

- [1] UN Habitat – for a better urban future. Urban development and management. Adresa: <http://www.unhabitat.org> (pristupljeno: 15.06.2018.)
- [2] Marović, I., Hanak, T., Identifikacija utjecaja indikatora na vrednovanje stambenog okruženja, *Zbornik radova Građevinskog fakulteta Sveučilišta u Rijeci*, 16: 113-127, 2013.
- [3] Hanak, T., Marović, I., Pavlović, S., Preliminary identification of residential environment assessment indicators for sustainable modelling of urban areas, *International Journal of Engineering Modelling*, 27(1-2): 61-68, 2014.
- [4] Samardzioska, T., Cvetkovska, M., Lazarevska, M., Gavriloska, A.T., Impelmentation of energy efficient measures in apartments in Macedonia, Proc. of the 3rd Int. Symp. On Lify-Cycle Civil Engineering: Life-Cycle and Sustainability of Civil Infrastructure Systems, IALCCE 2012, Vienna, 1702-1708, 2012.
- [5] Hughes, B.R., Chaudhry, H.N., Calautit, J.K., Passive energy recovery from natural ventilation air streams, *Applied Energy*, 113: 127-140, 2014.
- [6] Zuluga, M.C., Guallar-Castillon, P., Conthe, P., Rodruguez-Pascual, C., Graciani, A., Leon-Munoz, L.M., Gutierrez-Fisac, J.L., Regidor, E., Rodriguez-Artalejo, F., Housing conditions and mortality in older patients hospitalized for heart failure, *American Heart Journal*, 161(5): 950-955, 2011.
- [7] Mijić, M., Šumarac Pavlović, D., Todorović, D, Radivojević, A., Sound insulation between dwellings in existing housing stock in Serbia, Proc. of the Euronoise: European Conf. On Noise Control 2012, Prague, 1254-1259, 2012.
- [8] Bakar, A.H.A, Cheen, K.S., Rahmawaty, Sustainable housing practices in Malaysian housing development: towards establishing sustainability indeks, *International Journal of Technology*, 2(1): 84-93, 2011.
- [9] Bourassa, S.C., Cantoni, E., Hoesli, M. Spatial dependence, housing submarkets, and house price prediction, *Journal of Real Estate Finance and Economics*, 35(2): 143-160, 2007.

Prilozi

Prilog 1 – Rezultati mjerenja provedenog unutar stambene jedinice br. 17 – Hostov
breg

Tablica 4: Statistika prikupljenih podataka na mjernom instrumentu HB1 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,4	34,9	6,5
max	25,4	72,2	18
avg	22,54	51,27	11,82
median	22,4	51,2	11,8
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,2	26,2	1,8
max	25,4	59,4	14,5
avg	22,65	44,46	9,71
median	22,5	45,4	9,8
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,7	22,2	-0,7
max	24,1	47,4	10,3
avg	22,12	35,77	6,05
median	22	36,2	6,5
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,2	32,4	5,4
max	26	73	20,7
avg	22,64	54,46	12,86
median	22,4	54,3	13,1
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,2	23,6	0,8
max	24,6	64,3	16,9
avg	22,42	45,50	9,78
median	22,3	48,4	10,9
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,8	28,6	4,7
max	26	68	17
avg	23,09	47,50	11,07
median	23	47,8	11,2

Tablica 5: Statistika prikupljenih podataka na mjernom instrumentu HB2 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,40	35,90	6,40
max	24,8	78,8	20,4
avg	22,51	52,03	12,00
median	22,5	51,4	11,9
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,1	25,5	1,2
max	24,7	81,8	21,3
avg	22,48	46,81	10,27
median	22,5	46	10,1
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20	22,1	-1
max	24,2	71,9	18,3
avg	22,20	36,98	6,57
median	22,2	37,4	7,1
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,5	35,6	5,8
max	23,9	85,5	20,9
avg	22,32	56,56	13,13
median	22,2	57,5	13,4
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21	25,7	1,4
max	23,9	73,2	17,6
avg	22,23	47,29	10,23
median	22,1	50,7	11,4
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,7	33,3	6,2
max	23,6	81,1	19,6
avg	22,50	51,34	11,75
median	22,5	51,8	11,7

Tablica 6: Statistika prikupljenih podataka na mjernom instrumentu HB3 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,40	40,50	7,00
max	24,8	78,8	20,4
avg	22,51	52,03	12,00
median	22,5	51,4	11,9
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,8	29,6	2,5
max	22,9	63,7	15,1
avg	21,48	48,66	10,01
median	21,5	48,6	10,1
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,2	23,8	-0,5
max	22,2	54,9	11,7
avg	20,75	39,77	6,39
median	20,8	40,7	6,9
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,9	36,6	5,9
max	23	79,3	19,1
avg	21,60	58,63	13,03
median	21,6	59	13,2
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,7	27,7	2
max	22,5	61,7	14,6
avg	21,78	48,62	10,25
median	21,8	50,8	11
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,6	32	4,8
max	23,5	69,5	16,4
avg	22,31	50,94	11,44
median	22,3	51,2	11,6

Tablica 7: Statistika prikupljenih podataka na mjernom instrumentu HB4 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	17,20	41,70	5,60
max	21,3	71,4	15,7
avg	20,29	58,38	11,71
median	20,4	59,3	12,2
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	15,8	25,7	-1,9
max	21,9	69,5	14,7
avg	19,69	53,26	9,70
median	19,9	53	9,8
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	14,3	26,7	-1,9
max	21,8	57,5	11,4
avg	19,25	42,71	6,02
median	19,3	43,9	6,7
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	16,5	36,4	5,3
max	22,7	74,7	16,4
avg	20,57	62,00	12,90
median	20,6	62,7	13,1
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,5	27,6	1,6
max	22,9	66,6	15
avg	21,19	50,73	10,27
median	21,2	53,9	11,3
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,3	28,9	3,6
max	24,7	68,9	16,6
avg	22,17	52,28	11,62
median	22,2	54,3	12,2

Tablica 8: Statistika prikupljenih podataka na mjernom instrumentu HB5 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,80	41,10	6,10
max	22,3	64,8	15
avg	21,35	54,68	11,73
median	21,4	54,2	11,7
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,2	30,1	1,4
max	22,5	60	13,6
avg	20,89	48,61	9,47
median	20,8	48,5	9,6
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	16,9	26,1	-0,5
max	22,4	52,6	10,8
avg	20,31	39,50	5,93
median	20,3	40,6	6,5
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,9	39	6,7
max	22,2	66,7	15,4
avg	21,49	57,41	12,63
median	21,5	57,9	12,9
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,6	29,8	2,7
max	22,6	63,1	14,7
avg	21,71	48,30	10,10
median	21,7	50,6	10,9
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,8	31,8	5,2
max	23,7	61,3	15
avg	22,38	49,39	11,06
median	22,4	50,5	11,2

Prilog 2 – Rezultati mjerenja provedenog unutar stambene jedinice br. 15 – Drenova

Tablica 9: Statistika prikupljenih podataka na mjernom instrumentu HD1 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	23,4	35,6	8,9
max	29,9	89,8	25,9
avg	25,51	53,56	15,22
median	25,4	53,7	15
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	24,2	24,8	3,3
max	29,2	89,4	24,8
avg	26,00	44,29	12,35
median	26	42,2	12,1
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	24	20,7	2,7
max	29,2	71,9	21,8
avg	26,20	34,65	9,06
median	26,4	33,2	8,6
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	24	35,3	8,4
max	28,8	92	24,7
avg	25,48	52,23	14,78
median	25,3	51,8	14,9
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	23,7	33,5	6,9
max	28,6	87,1	24,1
avg	24,80	46,70	12,40
median	24,6	46	12,2
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	23,8	31,8	7,6
max	30,9	92,6	24,8
avg	24,84	49,72	13,37
median	24,6	48,3	13

Tablica 10: Statistika prikupljenih podataka na mjernom instrumentu HD2 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,20	37,30	6,60
max	24,1	72,5	18,5
avg	23,13	54,46	13,34
median	23,1	55	13,6
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20	26,6	0,7
max	26,4	71,1	19,2
avg	22,47	42,69	8,90
median	22,6	40,9	9
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,1	25,1	-0,3
max	25	61,2	15,1
avg	22,77	37,78	7,45
median	22,7	37,9	7,6
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,7	35,4	6,1
max	24,2	70,8	17,6
avg	22,92	50,99	12,14
median	23	51,5	12,4
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,7	30,1	3,6
max	23,8	62,1	15
avg	22,94	42,90	9,51
median	22,9	42,3	9,4
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,5	30	5,2
max	24,8	64,4	16,8
avg	23,43	45,86	10,90
median	23,5	46	10,9

Tablica 11: Statistika prikupljenih podataka na mjernom instrumentu HD3 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,90	43,50	7,40
max	23,4	77,7	17,7
avg	20,77	56,01	11,59
median	20,75	55,8	11,6
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	14,9	30,5	-1,7
max	24,3	68,8	15,2
avg	19,60	47,04	7,71
median	19,6	45,9	7,6
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	15,7	22,9	-3,9
max	21,1	52,9	10,1
avg	18,41	36,05	2,90
median	18,4	34,5	2,5
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,7	40,5	8
max	22,5	72	16,4
avg	20,87	54,36	11,23
median	20,9	53,9	11,1
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21	34,7	5,1
max	24	69,4	16
avg	21,75	47,10	9,84
median	21,7	47,7	10
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,7	30,9	3,9
max	25,8	59	14,6
avg	22,41	48,24	10,71
median	22,5	50,6	11,1

Tablica 12: Statistika prikupljenih podataka na mjernom instrumentu HD4 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	23,00	36,30	7,60
max	30,8	78,2	23,6
avg	24,83	54,91	15,02
median	24,5	55,3	15
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	23,3	26,8	3,4
max	32,4	71	23,4
avg	25,20	45,45	12,14
median	25,1	42,4	11,4
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	23,3	23,1	2,6
max	31,4	62,4	22,3
avg	25,11	35,28	8,49
median	25,1	34,2	8,1
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	22,8	36,3	8
max	29,6	76,2	24,4
avg	24,74	53,40	14,46
median	24,4	54,1	14,7
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	22,9	29	4,9
max	30,7	65,5	22,1
avg	24,53	43,93	11,29
median	24,2	44,6	11,5
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	23,2	32,7	7
max	31,3	67,9	22,8
avg	24,97	45,62	12,23
median	24,7	44,8	11,9

Tablica 13: Statistika prikupljenih podataka na mjernom instrumentu HD5 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,40	31,70	9,90
max	29,7	54,3	12,1
avg	24,50	41,73	10,45
median	23,5	43,4	10,3
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	23,4	26,3	26,3
max	27,9	71,7	71,7
avg	25,11	45,51	45,51
median	25,2	42	42
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	23,3	23,4	3,1
max	28	62,2	20
avg	25,10	34,51	8,15
median	25,2	33,5	8
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,9	37,4	7,7
max	26,8	81,3	22,3
avg	24,39	54,12	14,36
median	24,3	54,8	14,6
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,7	27,5	3
max	27	70,3	20,3
avg	24,15	44,70	11,20
median	24	45,5	11,5
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	22,9	32,6	6,5
max	27,6	71,3	20,9
avg	24,50	46,44	12,06
median	24,3	45,5	11,8

Prilog 3 – Rezultati mjerenja provedenog unutar stambene jedinice br. 5 – Drenova

Tablica 14: Statistika prikupljenih podataka na mjernom instrumentu D1 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,8	48,5	11,5
max	26,2	89,4	23,8
avg	23,70	59,28	15,19
median	23,8	58,7	15
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,6	21,8	-2,7
max	26,3	86,3	23,8
avg	22,92	47,36	10,76
median	23,1	47	11,6
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,1	35,7	6,2
max	26,2	88,3	23,6
avg	23,45	47,54	11,50
median	23,6	46,6	11,3
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,5	45,9	11,7
max	25,8	91,4	23,8
avg	23,38	57,18	14,34
median	23,4	55,8	14,1
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,8	41,9	8,7
max	26,2	91,9	24,2
avg	23,14	53,98	13,18
median	23	54,7	13,4
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	22	45	9,9
max	26,3	92,9	23,7
avg	23,15	57,63	14,21
median	23	57,1	14,2

Tablica 15: Statistika prikupljenih podataka na mjernom instrumentu D2 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,90	47,90	11,70
max	25,7	71,6	18,9
avg	23,73	58,79	15,09
median	23,8	58,8	15
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,4	22,1	-2,7
max	25,7	67,3	17,3
avg	22,95	46,17	10,43
median	23,1	45,3	11,1
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,7	33,9	4,4
max	25,6	59,5	15,3
avg	23,23	43,66	10,08
median	23,4	43,3	10,4
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,3	46,7	10,3
max	25,3	69,9	18,2
avg	23,28	55,85	13,90
median	23,3	56	14
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,6	40,4	8,3
max	25,1	67,3	17,6
avg	23,03	52,99	12,80
median	22,9	52,7	13
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	22	37,3	8,1
max	25,5	68,5	17,9
avg	23,38	55,06	13,71
median	23,3	55	13,8

Tablica 16: Statistika prikupljenih podataka na mjernom instrumentu D3 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,50	49,00	11,80
max	25,7	71,6	18,9
avg	23,73	58,79	15,09
median	23,8	58,8	15
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,4	22,1	-2,7
max	25,7	67,3	17,3
avg	22,95	46,17	10,43
median	23,1	45,3	11,1
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,7	33,9	4,4
max	25,6	59,5	15,3
avg	23,23	43,66	10,08
median	23,4	43,3	10,4
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21	47,3	10,2
max	25,4	72,7	18,7
avg	23,00	56,52	13,82
median	23	56,7	14
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,4	41,1	8
max	24,8	67,9	17,5
avg	22,78	53,28	12,64
median	22,6	53,1	12,9
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,7	40,1	8,5
max	25,3	69,1	17,2
avg	23,08	55,43	13,53
median	23	55,4	13,6

Tablica 17: Statistika prikupljenih podataka na mjernom instrumentu D4 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,40	49,80	11,70
max	24,4	72,4	18,4
avg	22,93	59,87	14,64
median	23	59,7	14,6
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,8	23,6	-2,3
max	24,6	68	17,5
avg	22,18	47,20	10,08
median	22,4	46,1	10,7
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,4	34,4	4,1
max	24,3	61,2	15
avg	22,44	45,15	9,86
median	22,6	44,7	10,1
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21	47,7	9,9
max	24,3	70,2	17,3
avg	22,64	56,48	13,49
median	22,7	56,5	13,6
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,4	41,4	8
max	24,3	69	18,2
avg	22,49	53,37	12,42
median	22,4	53,5	12,8
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	21,7	43,5	9,4
max	24,2	69,7	17,7
avg	22,79	55,87	13,40
median	22,7	55,9	13,4

Tablica 18: Statistika prikupljenih podataka na mjernom instrumentu D5 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,80	39,80	7,30
max	23	69,2	15,8
avg	20,78	55,02	11,33
median	20,7	55,2	11,2
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,8	27,3	0
max	23,3	63,3	14,2
avg	20,33	47,61	8,60
median	20,4	48,2	9,1
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,6	29,4	2
max	21,6	54,1	11
avg	20,31	42,85	7,16
median	20,3	42,6	7,2
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,8	45,7	8,7
max	22,8	71,7	15,5
avg	20,61	54,19	10,96
median	20,5	54,4	11
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,6	36,2	5,6
max	23,1	66,3	15,2
avg	21,36	52,55	11,12
median	21,4	52,2	11,2
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,5	35,7	6,2
max	24,8	63,7	15,3
avg	22,53	53,80	12,58
median	22,6	55,2	12,9

Prilog 4 – Rezultati mjerenja provedenog unutar stambene jedinice br. 8 – Rujevica

Tablica 19: Statistika prikupljenih podataka na mjernom instrumentu R1 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	0	0	0
max	0	0	0
avg	0,00	0,00	0,00
median	0	0	0
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,9	40	5,5
max	23	78,4	16,5
avg	20,21	63,05	12,79
median	20	62,8	12,9
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,4	28,9	0,2
max	23,4	62,7	13,2
avg	20,21	49,40	9,15
median	20	50	9,4
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,5	50,8	9,9
max	23,7	78,1	16,7
avg	20,06	64,21	12,99
median	20	63,7	13
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,9	31,5	3,4
max	22,3	70,4	14,9
avg	20,52	53,05	10,41
median	20,5	53,6	10,5
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,7	34,6	6,5
max	24,5	69,6	15,7
avg	21,64	53,38	11,50
median	21,8	55,5	12

Tablica 20: Statistika prikupljenih podataka na mjernom instrumentu R2 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,50	38,70	4,90
max	23,3	93,1	21,7
avg	20,63	60,89	12,65
median	20,6	61,2	13
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,1	38,9	5,3
max	23,5	94,5	22,2
avg	20,97	63,68	13,68
median	21	64,8	14
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,2	31,5	1,2
max	23,3	93,7	21,6
avg	20,42	54,87	10,75
median	20,4	54,8	11
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,7	48,5	8,9
max	22,7	94,1	21,5
avg	20,48	64,92	13,51
median	20,5	64,1	13,3
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,7	35,7	4,6
max	23	93,7	21,5
avg	20,64	60,10	12,32
median	20,6	59,2	12,2
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,9	40	7,8
max	23,6	93,8	22,2
avg	21,15	62,15	13,39
median	21	62,6	13,6

Tablica 21: Statistika prikupljenih podataka na mjernom instrumentu R3 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,80	38,40	5,60
max	21,8	69,7	14,7
avg	20,36	58,43	11,81
median	20,4	59,3	12,1
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,9	26,5	0,4
max	21	72	15,2
avg	20,29	58,22	11,51
median	20,3	59,6	12,1
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,3	23,6	-1,1
max	21,2	63,4	13,6
avg	20,03	45,45	7,60
median	20,1	47,5	8,5
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,8	54,2	10,5
max	21,3	75,2	15,8
avg	20,16	62,77	12,76
median	20,1	62,4	12,8
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20	36,6	4,8
max	21,1	66,4	14,2
avg	20,32	53,94	10,55
median	20,3	54	10,7
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,2	40,8	7,9
max	22,1	73,1	16
avg	20,89	56,53	11,79
median	20,8	58,4	12,3

Tablica 22: Statistika prikupljenih podataka na mjernom instrumentu R4 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,90	36,10	5,50
max	26,5	81	20,9
avg	21,32	58,04	12,59
median	21,1	58,6	12,6
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,7	42,9	7,4
max	25,9	80,5	19,9
avg	21,23	60,15	13,06
median	21	59,7	13
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,4	32,8	3,2
max	28	62,2	18,1
avg	21,11	47,75	9,50
median	20,9	47,9	9,5
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,4	46,6	10,5
max	26,6	77,2	19,7
avg	21,21	60,76	13,25
median	21	60,8	13,1
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	19,9	32,5	3,4
max	26,2	77,6	19,4
avg	21,22	51,84	10,75
median	21	52,3	10,8
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	20,4	36,7	6,8
max	27,5	71,6	19
avg	22,16	52,42	11,77
median	22,1	53,9	12,2

Tablica 23: Statistika prikupljenih podataka na mjernom instrumentu R5 tijekom perioda snimanja

1. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	16,80	40,40	5,10
max	21	71,7	13
avg	17,64	61,91	10,15
median	17,6	63,3	10,4
2. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	16,4	44,8	4,3
max	19,2	75,2	13,9
avg	17,77	64,20	10,82
median	17,9	65,1	11
3. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	15,6	28,3	-1,9
max	18,5	64,6	10,9
avg	16,64	52,28	6,67
median	16,6	54,2	7,3
4. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	17	53,2	8,4
max	18,9	77,6	13,9
avg	17,87	65,59	11,26
median	17,9	65,9	11,2
5. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	17,5	38,6	4,3
max	20	71,8	13,9
avg	18,76	55,23	9,43
median	18,9	54,2	9,4
6. tjedan			
	TEMPERATURE	RELATIVE-HUMIDITY	DEW-POINT
min	18,4	36	5,7
max	23	74,1	15,3
avg	20,10	56,23	10,90
median	20,1	58,1	10,9

Naslov: Preliminary analysis of indoor temperatures and humidity in urban social housing

Autori: Ivan Marović, Vladimir Benac, Mateo Viškanić

Rad:

1. Introduction

Modeling sustainability is a difficult task as one needs to implement a large number of influences from both Earth and Human Systems as the systems are in continuous relationship [1]. The Earth System provides the sources of the inputs to, and the sinks that absorb the outputs of, the Human System. Unfortunately, most current models often solve a specific set of influences than a whole real system. This makes current models likely to miss important feedbacks in the real Earth-Human system, especially those that may result in unexpected and counterintuitive outcomes [2]. Therefore, it is important to incorporate all identified influences from both systems into the modelling processes.

Over the last two centuries the impact of the Human System has grown dramatically, becoming strongly dominant within the Earth System in many different ways. A group of researchers reported [2] that consumption, inequality, and population have increased extremely fast, especially since about 1950, threatening to overwhelm the many critical functions and ecosystems of the Earth System. Changes in the Earth System have important feedback effects on the Human System, with costly and potentially serious consequences. As the authors [2] argue that in order to understand the dynamics of either system the need to be coupled through bidirectional couplings representing the positive, negative, and delayed feedbacks that exist in the real systems.

The focus of this paper is on urban areas as a part of the Earth System where the Human System drivers are mostly focused on. Because of the expectation that the 60% of world population will live in urban areas by 2030 and that every day urban areas inhabit over 160.000 new citizens [3] it puts the tremendous importance on identification of residential environment assessment indicators for sustainable modelling of urban areas. Increasing population density in urban areas can significantly affect the quality of housing, as well as its sustainability from a long-term perspective [4]. Such occurs on a small scale as well and therefore it can be analyzed on a single household i.e. apartment. The urban social housing does not differ. Therefore, in the management of construction projects, special attention should be given to the planning as the most important phase of decision-making process and construction project management in order to achieve sustainable solutions.

The aim of this paper is to show preliminary analysis of indoor temperatures and humidity in urban social housing as the result of conducted field research. These hygrothermal measures are the most important ones as they directly influence the occupants' quality of life, and it is important to adequately manage them in order to have sustainable and livable habitat. Having all stated in mind, the main hypotheses is stated: "The occupants' habits significantly influence the temperatures and humidity levels in urban social housing."

The paper is structured as follows: Firstly, the research background is introduced. Secondly, the research background is presented followed by detail description of research design. The results of the gathered indoor temperatures and humidity in urban social housing are presented and discussed in following section. Finally, the conclusions are drawn with regard to the examined locations and proposed model.

2. Research Design

2.1. Study area

This research aims to examine the temperatures and humidity levels in urban social housing and their connection regarding occupants' habits. Study area is located in the city of Rijeka in the area of

Hostov breg where the first construction phase of social housing was erected during 2014 by the City of Rijeka's Social Housing Agency (APOS). The occupants were informed about the research and they all agree to be a part of research.

Firstly, the conducted interviews with APOS and the occupants has served the authors as a starting point for developing the project case (pilot study) with a goal to identify temperature and humidity levels and to give guidelines in order to reduce levels of humidity. Two apartments were selected for the pilot study. Both apartments are part of the same building and oriented in same direction. The apartment's visualization is shown in Figure 1 together with locations where measurement instruments i.e. dataloggers (DL) were placed.




Figure 1. Datalogger positions in observed real estate.

The dataloggers were placed in two places where the most humidity is produced in an apartment – kitchen and bathroom. The data was gathered continuously during 6 weeks and the sampling rate was 1 minute. That resulted in gathering over 60,000 temperature and humidity readings by each datalogger and in total over 250,000 readings.

2.2. Establishing the model for humidity flow detection inside urban social housing due to occupants' habits

The proposed model for humidity flow detection inside urban social housing due to occupants' habits consists of several processes as shown in Figure 2. The proposed model starts with preliminary process of analyzing the Social Housing Agencies' real estate portfolio and selection of typical real estate. The selection can consist of one or more real estates. Such can be seen as initial process when the research problem is defined and the first interaction between the managers (APOS) and engineers (researchers and technicians).

This initial process is closely followed by detail analysis of selected real estate. During this process the data considering technical characteristics of selected real estate, its location characteristics as well as occupants comments about their apartment is taken into analysis resulting in complete real estate picture. Such is important and gives the researchers and technicians better insight during the identification of places in the real estate for datalogger installation. It is important to identify the correct place to put datalogger in order to collect the accurate hygrothermal data. Once the installation places are identified the technicians can install the measuring equipment i.e. dataloggers into their positions. All aforementioned serves for the process of gathering hygrothermal data.

Depending on datalogger specifications and the duration of measurement period the gathering data intervals should be defined. Usually, datalogger can measure and store up to 16,000 relative humidity and 16,000 temperature reading over 0 to 100% RH and -40 to +70°C measurement ranges with selectable data sampling rate (2 s, 5 s, 10 s, 30 s, 1 m, 5 m, 10 m, 30 m, 1 hr, 2 hr, 3 hr, 6 hr, 12 hr, and 24 hr). Regardless various options and therefore storing capabilities, it is recommended to check the measurement instrument at least one a week. Such is especially important during lasting

measurement periods. As the dataloggers are typically supplied with a long-life lithium battery, which can allow logging for one year, it can be considered to be satisfactory for conducting measurement in occupied real estate.

Once the data are gathered by the datalogger they can be easily exported to PC by adequate software. This is where the analysis of gathered data starts. But first, the gathered data should be exported from dataloggers software into txt-file or xls-file. Once the data is exported the analysis can be done by computing software such as Excel or Matlab. This analysis results in identification of specific i.e. characteristic event or trigger which can be used for modeling the spatial distribution of humidity inside observed real estate. For such computational fluid dynamics (CFD) analysis can be used to solve and analyze problems that involve fluid flows (in this case humidity and temperature).

Based on such numerical analysis the conclusions can be drawn resulting in guidelines for occupants.




Figure 2. Model for humidity flow detection inside urban social housing due to occupants' habits.

The proposed model is based on the idea of combining different engineering expertise (civil engineering and engineering) whose synergy effect, as authors believe, can form a quality guidelines for new occupants in order how to deal with high humidity in their real estate as well as to inform existing occupants about their current humidity levels and to advise them if they have problem with humidity. All aforementioned is done to enable quality housing conditions and to improve quality of life in urban social housing.

As the goal of the paper is to give preliminary analysis of indoor temperatures and humidity in urban social housing due to occupants' habits, the following section deals with two biggest generators of temperature and humidity in any household – kitchen and bathroom.

3. Results and Discussion

During the period of this pilot study (March and April 2018) the data was gathered in two apartments as part of the same social housing. As stated, apartments are oriented the same (towards North). General orientation of apartments is East-West and have openings (windows and balcony doors on the same side as can be seen in Figure 1).

Two dataloggers were placed in each apartment. The first one is placed in the kitchen area near the stove, while the other is placed in the bathroom near the sink (Figure 1). As the all technical elements of these apartments is the same, and the measurement was done during the same 6 weeks it is safe to assume that the dataloggers' readings show only the impact of occupants. The codification of dataloggers is presented in Table 1.

Table 1. Codification of dataloggers in selected apartments.

Apartment	Kitchen	Bathroom
Apartment A – Hostov breg (no.17)	DL1	DL2
Apartment B – Hostov breg (no.5)	DL3	DL4

The result of the gathered hygrothermal data is shown for each datalogger during a single week. This is done due to large amount of collected data. Therefore, the relative humidity and temperature readings for the kitchen area is shown in Figure 3 (for DL1) and Figure 4 (for DL3).






Figure 3. DL1 readings during week number 3.

The data gathered from DL1 during 3rd week of measurements shows rhythmic of daily behavior in the kitchen area. The temperature fluctuate around 22°C with the minimum of 19.7°C and the maximum of 24.1°C. This results in normal average humidity level of 36.2%, almost on the boarder to be too dry (minimum is 22.2% and the maximum is 47.4%). As the average humidity in this room is normal the growth of humidity during day is continuous with quick discharges. One of the reasons for quick discharge can be the existence of window in this room.



The data gathered from DL3 during 3rd week of measurements shows constant activities of the occupants in the kitchen area. The temperature fluctuate around 25°C with the minimum of 23.3°C and the maximum of 31.4°C. This results in normal average humidity level of 34.2%, almost on the boarder to be too dry (minimum is 23.2% and the maximum is 62.4%). As the average humidity in this room is normal the growth of humidity and discharges are rather fast during day. One of the reasons for quick discharge can be the existence of window in this room. Although, the accumulated humidity in this apartment is higher than in Apartment A.



The data gathered from DL2 during 6th week of measurements shows rhythmic of daily behavior in the bathroom area. The temperature is almost constant and slightly fluctuates around 22°C with the minimum of 21.7°C and the maximum of 23.6°C. This results in average humidity level of 51.8%, which is little higher than it should be (minimum is 33.3% and the maximum is 81.1%). As the average humidity in this room is little higher than it should be, the growth of humidity during day is concentrated in mornings and evenings as the rest of the day it discharges. One of the reasons for slow discharge is for sure the lack of window in this room, as the major discharge channel is through the bathroom room. Such should not be the practice as the discharge of humidity is only transferred from one room to another but not carried away from the apartment.




Figure 6. DL4 readings during week number 3.

The data gathered from DL6 during 6th week of measurements shows rhythmic of daily behavior in the bathroom area. The constant activities of the occupants in this area is also visible thus resulting in a high peaks regarding humidity. This results in average humidity level of 48.3% with the minimum of 31.8% and the maximum of 92.8%. The temperature also varies a lot with the minimum of 23.8°C and the maximum of 30.9°C with an average of 24.6°C. As the average humidity in this room is almost normal, the growth of humidity is continuous during whole with the discharges periods during the night. One of the reasons for slow discharge is for sure the lack of window in this room, as the major discharge channel is through the bathroom room, especially during night. Such should not be the practice as the discharge of humidity is only transferred from one room to another but not carried away from the apartment.

Presented data give an insight into the differences between the temperature and humidity levels in these two apartments. It is evident that occupants' habits influence the temperature and humidity levels in urban social housing. There is a rather big difference between the temperature levels between the kitchen area of Apartment A (22°C) and Apartment B (25.1°C), as well as the bathroom area of Apartment A (22.5°C) and Apartment B (24.6°C). As the window is part of kitchen area the humidity discharge is rather quick during the whole day, which is not the case with the bathroom area.

As the bathroom area has approximately five time smaller volume than the kitchen area (kitchen is open to the living room) and the much frequent and larger use of hot water (i.e. showers, washing machines) the humidity discharge takes more time. One of the problems is the lack of window in the bathroom, which is common thing in this type of construction, and the installed ventilation system (air-intake ventilator) cannot cope with amount of humidity produced by occupants.

Occupants often cope with this problem by opening the door with the goal that accumulated humidity will flow out from the bathroom. This is a slow way of discharging but also not the best one as the humidity is only transferred from one room to another but not carried away from the apartment. Therefore, the better way of dealing with this problem is to install any kind of air-extractor system such as home dehumidifier (either condensate or desiccant). These are portable electrical devices which reduce and maintain the level of humidity in the air on the comfort levels.

4. Conclusions

The presented preliminary analysis of indoor temperatures and humidity in urban social housing showed the influence of the occupants' habits on overall temperature and humidity levels in an apartment. This influence can rise up to level of high humidity which reflects into constant humidity saturation in apartments. Such should be avoided. Therefore the proposed model for humidity flow detection inside urban social housing due to occupants' habits is created in order to give guidelines for those households with high levels of humidity.

Differences among examined apartments were analyzed. As predicted, the biggest generators of temperature and humidity in any household are kitchen and bathroom. As the bathroom area is usually significantly smaller than the kitchen area, usually opened to the living room, the humidity discharge takes more time. One of the problems is the lack of window in the bathroom, which is a common thing in this type of construction, and the installed ventilation system (air-intake ventilator) cannot cope with amount of humidity produced by occupants. In order to cope with such problems and easily discharge the humidity surplus is to install any kind of air-extractor system such as home dehumidifier.

II DIO

Numerička simulacija
prostornog širenja vlage unutar
postojećih stambenih jedinica
uslijed životnih navika stanara

Uvod

Život u stambenim prostorima novijeg datuma gradnje sve češće iskazuje jedan problem, povećanje vlage unutar stana. Posljedično tome, u stambenim prostorima dolazi do narušavanja zdravlja stanara. Često se postavlja pitanje odakle taj problem proizlazi, a probat ćemo ga obraditi i razjasniti u ovom elaboratu. Praktično gledano problem može sagledati dva bitna čimbenika, neograničenu količinu energije/tople vode te premalo izmjena zraka unutar stambenog prostora.

Raznolikost tempa života pojedinca nudi niz mogućih „stilova“ življenja unutar jednakog prostora, no zajednička je karakteristika da se generira više vlage no ikad, poradi velike dostupnosti prvenstveno tuširanja i kupanja, a potom kuhanja i sušenja odjeće. Uz praktični savršeno zabrtvljene stambene prostore, koji ne dopuštaju adekvatne izmjene zraka bez čovjekova utjecaja, dolazimo u stanja kada stambeni prostor postaje zasićen vodenom parom u zraku. Ona mora otići negdje i odlazi, to jest kondenzira se na hladnim stijenkama zidova, čime pospješuje rast čovjeku nepoželjnih kultura i uzrokuje zdravstvene probleme.

Odrađeno je eksperimentalno istraživanje u četiri stambene jedinice, gdje su postavljeni mjerači („loggeri“) stanja zraka unutar prostora, i to sa zapisom relativne vlažnosti i temperature svake minute. Mjerači su postavljeni na lokacije koje su određene podobnim za daljnje analize i donošenje zaključaka. Sakupljanje uzoraka trajalo je punih 6 tjedana, nakon čega se pristupilo obradi podataka. Obradeni su i procjenjena stanja svake stambene jedinice zasebno, a potom su izvršene i usporedbe svih jedinica, indirektno dajući za rezultat navike stanara koji borave u prostoru.

Također, po obradi podataka odabran je specifičan događaj unutar jedne stambene jedinice koji će biti prikazan matematičkim modelom koji će u dovoljnoj točnosti reprezentirati događaj. Događaj će zapravo prikazati primjer generiranja pare unutar prostora, i što se s tom parom to jest vlagom, kasnije događa. Kalibracija modela biti će obavljena pomoću podataka sa mjerača. Odabrani je događaj protumačen kao kraće kuhanje u jednoj stambenoj jedinici te je dan detaljan vremenski presjek simulacije i zaključci.

Ovim elaboratom pokazuje se kako upotrebom matematičkih modela možemo projektiranje zgrada uz razuman trošak podići na viši nivo, uz poboljšanje u segmentima termotehničkih instalacija, građevinskih radova, ekonomskog aspekta te najbitnije, čovjekova zdravlja i ugone.



Problematika novogradnji – usporedba sa starijom gradnjom

Danas su čovjeku dostupne neograničene količine tople vode za tuširanje, shodno tome tuširanja su dulja i učestalija, neograničeno pranje odjeće (posljedično sušenje) te neograničena energija za kuhanje. Svi navedeni procesi proizvode (generiraju) određene količine vodene pare koja ovlažuje prostor u kojem se boravi. Pretjerano ovlaživanje nije problem ukoliko postoje izmjene unutarnjeg zraka sa svježim (vanjskim) zrakom. Ukoliko te izmjene nisu dostatne, doći će do rošenja na hladnijim stijenkama.

Nameće se pitanje kako to da se ponovno javljaju problemi koji su relativno nedavno učinkovito riješeni. Najprije treba razjasniti kako do kondenzacije vodene pare iz zraka uopće dolazi. Vlažni zrak smjesa je suštog zraka i vodene pare. Ovisno o temperaturi, suhi zrak može primiti određene apsolutne (!) količine vlage, izraženo u gramima vode po kilogramu vlažnog zraka. Što je zrak topliji, to može apsolutno primiti više vlage. Apsolutnu i relativnu vlažnost zraka ne smije se poistovjećivati. Relativna je vlažnost po definiciji omjer parcijalnog tlaka vodene pare i tlaka zasićenja vodene pare. Pojednostavljeno, to je omjer udjela vodene pare u zraku i one maksimalne količine koju zrak može poprimiti prije nego dođe do magle/orošavanja. Primjera radi, zrak temperature 30°C i relativne vlažnosti 30% sadrži apsolutno (g/kg) više vlage nego zrak temperature 20°C relativne vlažnosti 50%. Temperatura na kojoj mora biti kruta stijenka da bi na njoj došlo do kondenzacije ovisi o temperaturi i relativnoj vlažnosti. Što je relativna vlažnost veća, to je i temperatura rošenja viša, to jest bliža temperaturi okoline, čime se izlažemo većem riziku da dođe do orošavanja po zidovima ili sličnom. Taj problem može se riješiti povećanjem temperature u prostoru, čime povećavamo kapacitet zraka da poprimi vlagu, to jest smanjujemo relativnu vlažnost, i na taj način se više udaljavamo od točke rosišta. Sva ova stanja opisana su u Molliere-ovom hx dijagramu, jednom od osnovnih dijagrama projektanata termotehničkih sustava.

U počecima moderne građevine vanjska izolacija bila je minimalna (sustavi grijanja mnogostruko snažniji od današnjih) dok je stolarija bila drvena. Loša izolacija dopuštala je da se stijenke unutarnjih zidova spuštaju na niže temperature no što je to danas, jer koliko god unutar prostorije zagrijavali, toplina se neminovno gubi preko relativno loše izolirajućih cigli, drva i žbuka. To je dovodilo do tih nižih temperatura unutarnjih stijenki što je predstavljalo rizik da se i uz relativno malu vlažnost, temperatura stijenke spusti ispod temperature rošenja i dovede do kondenzacije na stijenci. S druge strane, drvena stolarija, koliko god dobro bila napravljena, ona nikad nije potpuno dobro brtvila, to jest uvijek je u prostoriji postojala neka izmjena zraka. Ta izmjena zraka značila je da postoji izmjena i topline i vlage, to jest prostor se hladio, no istovremeno i odvlaživao time što taj hladan zrak nema sposobnost prenositi te količine apsolutne količine vlage, to jest unutar samog stambenog prostora. Na taj način, u nekom prijelazno razdoblju kada se izolacija ipak počela koristiti, problem vlage mnogostruko se smanjio, a sada se ponovno pojavljuje.

Danas se pokušava što manje energije gubiti u zgradi te se zbog toga vanjska ovojnica zgrada prekriva visokoizolirajućim materijalima te se radi na implementaciji rješenja toplinskih mostova, mjesta iznimno intenzivnih gubitaka topline u okolinu. Shodno tome, drvena stolarija zamijenila se PVC ili aluminijskom. Ta stolarija brtvi gotovo idealno, ne dopuštajući pritom izmjene toplog vlažnog unutarnjeg zraka sa svježim vanjskim. Samim time, ukoliko ne postoji umjetni odstranjivač vlage ili prirodno zračenje (otvoreni prozori i/ili vrata) u stanu će biti previše vlage i neminovno će doći do kondenzacije na hladnim stijenkama zidova.

Odabir parametara simulacije


Eksperimentalno istraživanje

Kako je navedeno, prije pristupa numeričkom modeliranju pojedinog događaja, sakupljena su bila stanja unutarnjeg zraka u promatrana četiri stana. Promatrani stanovi bili su opremljeni sa po pet mjerača smještenih na procjenom odabrane podobne lokacije. Podobne lokacije predstavljale su kompromis između podobnosti mjesta sa termotehničkog stajališta, mogućnosti koje uopće pruža sama stambena jedinica te jasno što diskretniji smještaj (iako veoma malih dimenzija) mjerača kako ne bi ometalo uobičajen život stanara. Sve lokacije provjerene su i termovizijskom kamerom kako bi se smanjila mogućnost nepovoljnog smještanja mjerača pored neke temperaturne anomalije (snažnog izvora ili ponora topline). Period u kojem su podaci sakupljeni protezao se kroz šest uzastopnih tjedana, sa intervalom mjerenja od jedne minute. Mjerači su prikupljali podatke o trenutnoj temperaturi i relativnoj vlažnosti, računajući pritom i temperaturu točke rošnja.

Nakon prikupa i obrade podataka zaključeno je kako 4 stana imaju posve drugačiji životni stil, što je svakako bilo primjećeno i u razgovoru sa stanarima. Poradi diskrecije stanara, podaci o njima te načinu života i ostalim privatnim informacija, ostati će skriveni.

Promatrani događaj


Iz svih obrađenih podataka, naglasak za prikaz numeričkog modeliranja stavljen je na samo jedan stan te na pronalazak specifičnog događaja. Promatrani stan bio je najtopliji i relativno najvlažniji, odvijalo se najviše kuhanja, tuširanja su bila dulja i zbog broja stanara učestalija, dok su provjetravanja bila relativno slabija (no ipak posotjeća). Odjeća je bila sušena na pripadajućem balkonu. Tlocrt stana prikazan je na slici 1. Događaj koji je odabran za analizu prema podacima sa mjerača podsjećao je na proces kraćeg prokuhavanja, primjerice suhomesnatog proizvoda, a grafovi na kojima se temelji odabir prikazani su na slikama 2 i 3, u vremenskom intervalu malo prije i poslije događaja. Na slici 2 prikazan je mjerac HD4 smješten u kuhinji na ormariću nedaleko od štednjaka, izvora topline i vlage u ovom primjeru. Mjerac HD5 prikazan je na slici 3 i prikazuje stanje u dnevnom boravku koji je kako je vidljivo na slici 2 povezan preko blagovaonice sa kuhinjom, dok je na drugu stranu povezan sa hodnikom koji vodi do spavaćih soba i kupaonice. On je služio kao kalibracijski mjerac u primjeru po kojem će ostatak stana biti zanemaren, to jest biti prikazan prema mjeracu, realnom stanju, potencijalno izbjegavajući nesavršenosti modela cijelog stana.




Slika 1: Tlocrt promatranog stana

Na slikama 2 i 3 vidljiva su očitavanja mjerača te je primjena jednaka pojava kod oba i to je porast vlage nakon procesa prokuhavanja za cca 10%, vlage koja očigledno ostaje zatočena unutar stambenog prostora. Temperatura kao zakva ne podiže se značajno, u kuhinji nešto topline zaostaje (mjerac HD4), dok se u dnevnom boravku temperatura vraća na onu sa početka promatranog perioda, zbog relativno velikog prostora koji je spojen sa svim prostorijama te se na taj način teže utječe na njegovo temperaturno stanje.

Zanimljiva je i pojava na slici 3 kod prikaza relativne vlažnosti, na kraju prikazanih podataka vidimo kako relativna vlažnost kreće u ponovni rast. Valja napomenuti kako je uzrok tome vrlo vjerojatno peglanje u stanu, jer se daska za peglanje nalazi točno ispod mjerača. To je događaj koji također generira vlagu u stan, a primjećen je u prikupljenim podacima sa mjerača HD5 svakodnevno.



Slika 2: Podaci sa mjerača "HD4" za promatrani period




Slika 3: Podaci sa mjerača "HD5" za promatrani period

Numerički model

Kako je navedeno, numeričkim će se modelom prikazati odabrani događaj kako bi se prikazala mogućnost implementacije numeričkih simulacija u poboljšanje projekata i života stanara. Numeričkim bi se simulacijama bi se mogli predviđati specifični događaji to jest mogli bi se prikazati utjecaji budućih stanara unutar stambenih jedinica, sve do razine prilagodbe stana specifičnim potrebama budućih stanara.

Model stana koji je korišten za prikaz metode prikazan je na slici 4. Kako je prethodno navedeno, simulacija je uključivala samo dio stana čiji je rub bio kalibriran mjeračem HD5. Taj dio stana uključivao je kuhinju, blagovaonicu te veći dio dnevnog boravka, zajedno sa svim osnovnim građevnim elementima. Također, valja napomenuti kako su paralelno uz prikupljanje podataka o stanju zraka unutar prostora prikupljeni i vanjski uvjeti (u petominutnom zapisu), temperatura i relativna vlažnost. Podatak o temperaturi korišten je kao rubni uvjet u modelu, dok podatak o vlažnosti ne utječe na proračun jer u model nije bila implementirana izmjena zraka sa okolinom, koje

praktično i nema dok se ne otvore prozori ili vrata. Temperature hodnika, susjednih zgrada, stropa te poda date su iskustveno.



Slika 4: Model dijela stana koji obuhvaća kuhinju te dio blagovaonice i dnevnog boravka sa označenim mjerачima

Tlocrtne dimenzije modela odgovaraju stvarnom stanju stambenog prostora dok su debljine i karakteristike vanjske ovojnice pretpostavljene sukladno praksi. Model je ograničenih dimenzija zbog jednostavnosti proračuna i mogućnosti dobre kalibracije ruba prostorije, bez detaljnog uključivanja cijelog stambenog prostora u proračun. Mjerač „HD5“ time nam služi kao podatak na rubu čime eliminiramo neznanja detalja za predviđanje ponašanja ostalih prostorija.

Simulacija događaja

Promatrani slučaj biti će simuliran za vremensko razdoblje duljine 40 minuta, od 14:50 do 15:30 dana 19/03/2018. Slučaj opisujemo kao jedno od niza kuhanja taj dan, nešto kraće no intenzivnije, trajanje maksimalnog intenziteta kuhanja cca 18 minuta. To kuhanje samo je jedno od nekoliko generiranja vlage i topline iz kuhinje taj dan te ćemo rezultate simulacije pokušati primjeniti na tok cijelog dana unutar stambene jedinice.

Simulacija će biti podijeljena i ospisana u četiri dijela, radi lakšeg snalaženja i prikaza karakterističnih situacija. Prvi dio prikazivati će početno stanje, stanje u kojem se prostor nalazi na početku simulacije, u 14:50. Stanje za taj trenutak biti će određeno stacionarnim proračunom. Sljedeća je faza „uključivanje štednjaka“, to jest početak procesa kuhanja. On će biti simuliran na način da se posuda u prvih 10 minuta postepeno zagrijava, generirajući pritom sve više i više vlage. Treća faza je faza u kojoj je posuda progrijava te je generiranje pare konstantno pa je to stanje u kojem zapravo nema promjene na samoj posudi, to jest štednjaku. Ta faza traje 16 minuta. Posljednja faza simulira fazu kada štednjak isključujemo te se posuda hladi, a generacija pare smanjuje. Proces je također napravljen da se postepeno posuda hladi i traje do kraja simulacije, to jest 14 minuta.

Sve faze biti će detaljnije opisane u nastavku redom kojim se odvijaju u simulaciji:

- Početno stanje – vrijeme proračuna $t = 0$ s
- Faza zagrijavanja – vrijeme proračuna $t = 0$ do 10 min
- Faza intenzivnog kuhanja – vrijeme proračuna $t = 10$ do 26 min
- Faza hlađenja – vrijeme proračuna $t = 26$ do 40 min

Tok simulacije

Početno stanje ($t = 0$ s)

Simulaciju započinjemo proračunom stacionarnog stanja prostorije, uz određene rubne uvjete i pretpostavke. Stacionarno stanje znači da proračun dobivamo bez vremenske komponente, a sve to kako bi postavili stanja unutar modela čim bliže onim stanjima modela koji odgovaraju realnim uvjetima preuzetim sa mjerača, za odabrani početni trenutak ($t=0$). Korišteni su sljedeći parametri pri postavljanju simulacije u početno stanje:

- vanjska temperatura (preuzeta sa meteorološke stanice) – 4°C
- temperatura hodnika – 18°C
- temperatura zidova na grijane prostorije – 22°C
- temperatura stropa i poda – 20°C

Bitno je napomenuti kako je utjecaj ljudi te uređaja unutar stambenog prostora (hladnjak, televizija, igraća konzola itd.) implementiran izvorom topline po čitavoj domeni zraka u iznosu od 12 W/m^3 . Vлага je postavljena prema mjeraču HD5, bez izvora po domeni (tokom proračuna izvor će biti posuda s vodom).

Valja još jednom napomenuti kako je ovime dobivano početno stanje proračuna, dakle prvi korak u simulaciji koji predstavlja vrijeme 14:50 proračuna ili nultu minutu.

Zanimljivo je primjetiti kako ovaj dio stambene jedinice ima relativno male gubitke topline prema okolini, što zbog dobre izolacije, što zbog male izloženosti hladnom vanjskom zraku (nalazi se između dvije susjedne zgrade).

Drugi dio – faza zagrijavanja ($t=0$ do 10 min)

Proces kuhanja biti će simuliran kao generiranje toplog i vlažnog zraka iz tople posude koja se nalazi na realnoj lokaciji štednjaka u stambenoj jedinici. Dio zagrijavanja i početka isparavanja obuhvaća proces uključivanja štednjaka, to jest generaciju topline u posudi i pokretanje procesa isparavanja vode. Progrijavanje posude do potpuno zagrijane, time dovođenje generiranja vlage na najvišu razinu, prema pretpostavci uz referencijiranje na mjerač HD4 trajalo je 10 minuta. Sam tok temperatura i generiranja pare dan je u tablici 1.

Tablica 1 Parametri procesa kuhanja pri zagrijavanju

Vrijeme od: [sek]	Vrijeme do: [sek]	Temperatura posude [$^{\circ}\text{C}$]	Temperatura generirane vlage [$^{\circ}\text{C}$]	Brzina izlaza iz posude [m/s]
0	60	35	35	0
60	120	45	45	0
120	240	55	55	0,004
240	360	65	65	0,008
360	480	70	70	0,01
480	600	78	78	0,016

U tablici 1 vidimo kako je u relativno jednakim intervalima povećavana temperatura, a pri temperaturi od 55°C započeto je polagano isparavanje vode, koja dostiže svoj maksimum pri temperaturi od 78°C i brzini od $0,016 \text{ m/s}$.

Temperatura od 78°C odabrana je kao temperatura koja će uključiti činjenicu da se isparena voda miješa sa zasigurno nešto hladnijim zrakom izvan posude. Ta aproksimacija potrebna je obzirom da

proračun ne uključuje promjene agregatnih stanja, već se na izlazu iz posude generira veoma vlažni i topao zrak. Slična aproksimacija provedena je za posudu, koja zbog neke svoje debljine pada sa temperature 100°C unutar posude na neku manju, ovdje određenu jednaku temperaturi vlažnog i toplog zraka iz posude.

Zanimljivo je proučiti kako stanje na mjerачу HD5, smještenom u dnevnom boravku, praktično nije došlo do nikakve promjene čitavih 10 minuta koliko je proces zagrijavanja posude trajao, što je vidljivo iz tablice 2.

Tablica 2 Kretanje stanja zraka mjerача HD5 u drugoj fazi

Vrijeme od: [sek]	Vrijeme do: [sek]	Temperatura mjerача HD5 [°C]	Relativna vlažnost mjerача HD5 [°C]
0	60	25	31,5
60	120	25	31,5
120	240	25	31,9
240	360	25	31,9
360	480	25	32,6
480	600	25,1	34,5

Kako je prethodno navedeno, početno stanje (trenutak $t = 0$ s) računan je stacionarnim proračunom, bez promjene kroz vrijeme, kako bi se dobilo to početno stanje prostorije. Ovaj i svi sljedeći dijelovi proračuna nestacionarni su, to jest na svaki vremenski trenutak utjecaj ima onaj prethodni trenutak. Na taj način izrađene su potpune animacije čiji će sažetak biti dan na kraju ovog poglavlja.

Treći dio – faza intenzivnog kuhanja

Nakon faze zagrijavanja, slijedila je relativno stabilna faza generacije topline i vlage sljedećih 16 minuta, gdje su i brzine generiranja pare i temperature bile konstantne vrijednosti, dakle kuhalo je ujednačeno. Jedinu promjenu u modelu unosiо je kalibracijski mjerач, korigirajući promatrani model prema ostatku stambene jedinice, to jest prema realnom stanju na tom mjestu. Zbog sada već formiranog strujanja u modelu, dio zraka napuštaо je prostor, a zbog zakona fizike, ukoliko neka količina tvari napusti prostor, jednaka se količina mora vratiti. Stoga sve što je napuštalo prostor kroz dnevni boravak, u prostor se i vraćalo, s time da je sav zrak koji se vratio bio kalibriran na vrijednosti mjerача HD5, koje su prikazane u tablici 3. Vrijednosti u tablici odgovaraju vrijednostima sa slike 3, prethodnog poglavlja.

Tablica 3 Kretanje stanja zraka mjerача HD5 u trećoj fazi

Vrijeme od: [sek]	Vrijeme do: [sek]	Temperatura HD5 [°C]	Relativna vlažnost HD [%]	Apsolutna vlažnost [kg _{vode} /kg _{zraka}]
600	720	25,4	35,9	0,007228
720	840	25,6	36	0,007336
840	960	25,8	36	0,007425
960	1080	26	38,2	0,00798
1080	1200	26,1	43,2	0,009094
1200	1320	26,2	44	0,00932
1320	1440	26,3	47	0,010026
1440	1560	26,3	48,5	0,010351

Četvrti dio – faza hlađenja

Posljednja je faza uključivala polagano hlađenje posude te smanjenje generiranja vodene pare (posljedica hlađenja). Prema podacima mjerača taj događaj krenuo se dešavati nakon 26 minuta od početka proračuna te je procjenom trajao sve do 40 minute, nakon toga uslijedilo je izuzetno sporo hlađenje posude. Prikaz toka hlađenja posude te smanjenja generacije pare i topline dan je u tablici 4.

Tablica 4 Tok hlađenja posude i generacije pare tokom faze hlađenja

Vrijeme od: [sek]	Vrijeme do: [sek]	Temperatura posude [°C]	Temperatura generirane vlage [°C]	Brzina izlaza iz posude [m/s]
1560	1680	78	78	0,016
1680	1800	75	75	0,016
1800	1920	70	70	0,014
1920	2040	60	60	0,008
2040	2160	55	55	0,004
2160	2280	50	50	0
2280	2400	45	45	0
2400	2640	40	40	0

Također, podaci kalibracijskog mjerača HD5 dani su u tablici 5.

Tablica 5 Podaci kalibracijskog mjerača HD5 tokom četvrte faze

Vrijeme od: [sek]	Vrijeme do: [sek]	Temperatura HD5 [°C]	Relativna vlažnost HD5 [%]	Apsolutna vlažnost HD5 [kg _{vode} /kg _{zraka}]
1560	1680	26,3	49,4	0,010546
1680	1800	26,4	49,3	0,010588
1800	1920	26,4	50,9	0,010938
1920	2040	26,4	52,4	0,011266
2040	2160	26,4	52,4	0,011266
2160	2280	26,3	49,5	0,010568
2280	2400	26,2	46,8	0,009923
2400	2640	26,1	45,9	0,009671

Analiza dobivenih rezultata

Dobiveni rezultati simulacije biti će prikazani na slikama za karakteristične trenutke, početak/kraj svake od četiri faze te za neke karakteristične trenutke tokom faza, kako bi se detaljno mogla analizirati simulacija. Također, rezultati će biti dani u obliku prikaza raspodjela temperatura i relativne vlažnosti za čitavu domenu, kao i za dva presjeka.

Analiza temperatura

Analizu možemo započeti od početnog trenutka, $t = 0$. Taj trenutak dobiven je stacionarnim proračunom, rješavanjem problema neovisnog o vremenu kako bi postigli parametre domene zraka koji odgovaraju podacima sa mjerača. HD5 i HD4. Primjetno je prema prikazima slika 5, 12 i 19 kako je temperatura po čitavoj domeni ujendačena, nešto niža u blizini poda i stropa te jasno u blizini prozora i vrata gdje je još niža, no zbog visokog stupnja izolacije moderne stolarije to je samo nekoliko stupnjeva. Temperatura koja vlada u prostoru jest pretežito oko 25.5°C do 26°C .

Sljedeći trenutak koji je prikazan, na slikama 6, 13 i 20, prikazuje trenutak 5 minute, na polovici zagrijavanja posude. Vidljivo je kako je posuda dosta intenzivan izvor topline te kako se polako pri vrhu prostorije širi topli zrak što ga generira posuda. Ta fronta koja se širi postiže temperature i do 30°C , što je posebno dobro vidljivo u presjeku 2 na slici 20.

Na kraju faze zagrijavanja, nakon 10 minuta, vidimo prema slikama 7, 14 i 21 intenzivnije širenje te iste tople fronte, sa još većim intenzitetom generiranja topline u kuhinji, te frontom koja prelazi i temperature od 35°C . Na slikama treba obratiti posebnu pažnju na skalu, jer zbog različitosti skala na prikazima za 5 i 10 minuta, može djelovati kako je intenzitet s vremenom smanjen, iako je to netočno, samo je veća količina prosotra progrijana.

Sada je započela faza konstantnog kuhanja te proučavamo trenutak nakon 6 (od početka 16) minuta te faze kuhanja. Prikaz je dan na slikama 8, 15 i 22. Temperature fronte koja se širi zrakom iznad dostigla je već izrazito visoku temperaturu i širi se prostorom, ne samo promatranim već i čitavom stambenom jedinicom. Prema slikama 9, 16, 23 možemo primjetiti da vlada gotovo isto stanje i sljedećih 10 minuta, mali temperaturni rast (manje od 1°C) zabilježen je na mjeracu, te ne možemo očekivati neke veće promjene u tom pogledu niti u simulaciji, pogotovo zato što topli zrak koji je lakši od hladnog se praktično „zalijepio“ za strop i teško se širi čitavom domenom, to jest prema tlu. Također, zbog relativno intenzivne generacije pare, ona „prolazi“ kroz prostor šireći se pritom čitavom stambenom jedinicom, no zaostaje na jednom mjestu, na zidu pored ulaznih vrata, što ovdje nije posebno značajno (možda nekoliko stupnjeva viša temperatura u kutu) no biti će kod proučavanja vlage.

Sljedeće slike, 10, 17 i 24 prikazuju polovinu faze hlađenja, to jest 32 minutu same simulacije. Vidljivo je smanjenje intenziteta izvora topline i pare, a time i bolje progrijavanje stana, uz smanjenje temperature i brzine strujanja te glavne fronte.

Posljednje slike simulacije 11, 18 i 25 prikazuju kako se stambena jedinica „oporavlja“ od intenzivno predane topline od posude, koja se sada širi čitavom domenom podižući temperaturu unutar jedinice ukupno za nešto više od 1°C što je velik utjecaj od samo jednog kuhanja. Tako nakon procesa kuhanja, sa aspekta temperature, imamo nešto topliju čitavu stambenu jedinicu, dovoljno da sa više ovakvih procesa u danu čak i rasteretimo termotehnički sustav.

Analiza vlage

Stanje vlage u početnom trenutku prikazano je na slikama 26, 33 i 40. Iako odaje dojam velike raznoslikosti u relativnoj vlažnosti po domeni, zapravo je skala relativno uska, što čini razlike naizgled mnogo većima. Prostorija je relativne vlažnosti cca 30%.

Pregledavanjem slika 27, 34 i 41 koje odražavaju stanje nakon 5 minuta od početka simulacije, dakle na pola vremena potrebnog za zagrijavanje posude. Vidljivo je kako proširivanjem raspona skale, boje po prosotriji dolaze na ujednačeniju razinu. Valja primjetiti na slici 6 kako kod izvora, posude, relativna vlažnost nije izrazito visoka. Taj će se „fenomen“ provlačiti kroz cijeli proračun zbog načina generiranja pare, ne kao pare već kao zrak sa velikim udjelom vlage, koji je ujedno i visoke temperature što mu obara relativnu vlažnost, no čim se taj zrak krene mješati situacija u dovoljnoj mjeri odgovara procesu isparavanja, stvaranja magle te ponovnog isparavanja koje se inače odvija pri kuhanju. Primjetiti također treba kako, obzirom na relativno visoki intenzitet istrujavanja iz posude, u dva, od što će se kasnije pokazati tri, kritična mjesta već nešto viša razina vlage, iznad 40%. Ta dva mjesta su rubni dio kuhinje, izložen hladnoći vanjskog zraka, te rubni dio blagovaone, koja je zidom odvojena od ulaznih vrata, te je tamo i hladnije i mjesto gdje zrak, a pogotovo vlaga teže cirkuliraju pa se stoga zadržavaju na tom mjestu.

Slike 28, 35 i 42 prikazuju 10 minutu proračuna, kada je intenzitet kuhanja već visok. Najbitnija pojava sada je pojava trećeg specifičnog mjesta gdje se javlja povišena vlaga, na rubu gdje se nalaze balkonska vrata. Iznosi se na tim kritičnim mjestima penju i na više od 60%, a pri tome ne treba s uma skinuti činjenicu da je ovaj stan izrazito pregrijan (projektne temperature iznose 22°C, ovaj stan dostiže temperature veće od 26°C u normalnim situacijama). Također, temperatura zraka kod balkonskih vrata nego u kutu blagovaone, što znači da je u blagovaoni uz jednaku relativnu vlažnost, zapravo više vlage i postoji veća opasnost od rošenja. Kuhinja je također dobro progrijana, pa ni ondje situacija nije idealna.


Slike 29, 36 i 43 pokazuju trenutak 16 minute, gdje se svi prije spomenuti efekti i dalje manifestiraju. Pažljivim pregledom skale, vidimo da je relativna vlažnost u samom stanu narasla, kao i u rubnim, problematičnim djelovima.

Nakon 26 minuta, to jest kraja faze gdje se jednolično, no intenzivno kuha, svi efekti i dalje se pojačavaju, pa se tako dosežu vrijednosti i do 90% relativne vlažnosti, što gotovo da garantira rošenje po vratima balkona (manji problem, voda ne djeluje na staklo ni PVC), no u kutu blagovaone jako se lako javi problem. U nešto manjem intenzitetu taj je problem postojeći i u kuhinji, iznad prozora. Prikazano na slikama 30, 37, 44


Kuhanje je prestalo, a 6 minuta nakon toga (32 minuta proračuna) prema slikama 31, 38 i 45 vidi se smanjenje generacije vlage. Blagovaona širi vlagu prema van, dok je uz balkonska vrata i dalje na visokoj razini. Također, smanjenjem intenziteta širenja vlage i topline, ona može slobodno ostajati u kuhinji te se javljaju pojačane zone vlage na svim zidovima izloženima vanjskom zraku (vani je i dalje 4°C).

U posljednjem setu slika 32, 39 i 46 vidimo kako se situacija smiruje, no mora biti primjećeno kako je vlaga oko vioskih 50% u cijelom promatranom prostoru, što je uz povećanje temperature prostorije još značajnije, a relativan je porast 20%, što bez daljnje sanacije može postati problem.


Raspodjela temperatura po čitavoj domeni:




Slika 1 Raspodjela temperatura u čitavoj domeni u trenutku $t = 0$ s




Slika 2 Raspodjela temperatura u čitavoj domeni u trenutku $t = 300$ s




Slika 3 Raspodjela temperatura u čitavoj domeni u trenutku $t = 600$ s




Slika 4 Raspodjela temperatura u čitavoj domeni u trenutku $t = 960$ s



Slika 5 Raspodjela temperatura u čitavoj domeni u trenutku $t = 1560$ s




Slika 6 Raspodjela temperatura u čitavoj domeni u trenutku $t = 1920$ s




Slika 7 Raspodjela temperatura u čitavoj domeni u trenutku $t = 2400$ s

Napomena: za proučavanje svih prikaza obavezno je referiranje na priloženu skalu, koja je zbog složenosti proračuna i bolje reprezentacije podataka postavljena na automatski raspon


Raspodjela temperatura na presjeku 1:




Slika 8 Raspodjela temperatura na presjeku 1 u trenutku $t = 0$ s




Slika 9 Raspodjela temperatura na presjeku 1 u trenutku $t = 300$ s




Slika 10 Raspodjela temperatura na presjeku 1 u trenutku $t = 600$ s




Slika 11 Raspodjela temperatura na presjeku 1 u trenutku $t = 960$ s



Slika 12 Raspodjela temperatura na presjeku 1 u trenutku $t = 1560$ s




Slika 13 Raspodjela temperatura na presjeku 1 u trenutku $t = 1920$ s




Slika 14 Raspodjela temperatura na presjeku 1 u trenutku $t = 2400$ s

Napomena: za proučavanje svih prikaza obavezno je referiranje na priloženu skalu, koja je zbog složenosti proračuna i bolje reprezentacije podataka postavljena na automatski raspon


Raspodjela temperatura na presjeku 2:




Slika 15 Raspodjela temperatura na presjeku 2 u trenutku $t = 0$ s




Slika 16 Raspodjela temperatura na presjeku 2 u trenutku $t = 300$ s




Slika 17 Raspodjela temperatura na presjeku 2 u trenutku $t = 600$ s




Slika 18 Raspodjela temperatura na presjeku 2 u trenutku $t = 960$ s



Slika 19 Raspodjela temperatura na presjeku 2 u trenutku $t = 1560$ s




Slika 20 Raspodjela temperatura na presjeku 2 u trenutku $t = 1920$ s




Slika 21 Raspodjela temperatura na presjeku 2 u trenutku $t = 2400$ s

Napomena: za proučavanje svih prikaza obavezno je referiranje na priloženu skalu, koja je zbog složenosti proračuna i bolje reprezentacije podataka postavljena na automatski raspon


Raspodjela relativne vlažnosti po čitavoj domeni:




Slika 22 Raspodjela relativne vlažnosti čitavoj domeni u trenutku $t = 0$ s




Slika 23 Raspodjela relativne vlažnosti čitavoj domeni u trenutku $t = 300$ s




Slika 24 Raspodjela relativne vlažnosti čitavoj domeni u trenutku $t = 600$ s




Slika 25 Raspodjela relativne vlažnosti čitavoj domeni u trenutku $t = 960$ s



Slika 26 Raspodjela relativne vlažnosti čitavoj domeni u trenutku $t = 1560$ s




Slika 27 Raspodjela relativne vlažnosti čitavoj domeni u trenutku $t = 1920$ s




Slika 28 Raspodjela relativne vlažnosti čitavoj domeni u trenutku $t = 2400$ s

Napomena: za proučavanje svih prikaza obavezno je referiranje na priloženu skalu, koja je zbog složenosti proračuna i bolje reprezentacije podataka postavljena na automatski raspon


Raspodjela relativne vlažnosti na presjeku 1:




Slika 29 Raspodjela relativne vlažnosti na presjeku 1 u trenutku $t = 0$ s




Slika 30 Raspodjela relativne vlažnosti na presjeku 1 u trenutku $t = 300$ s




Slika 31 Raspodjela relativne vlažnosti na presjeku 1 u trenutku $t = 600$ s




Slika 32 Raspodjela relativne vlažnosti na presjeku 1 u trenutku $t = 960$ s



Slika 33 Raspodjela relativne vlažnosti na presjeku 1 u trenutku $t = 1560$ s




Slika 34 Raspodjela relativne vlažnosti na presjeku 1 u trenutku $t = 1920$ s




Slika 35 Raspodjela relativne vlažnosti na presjeku 1 u trenutku $t = 2400$ s

Napomena: za proučavanje svih prikaza obavezno je referiranje na priloženu skalu, koja je zbog složenosti proračuna i bolje reprezentacije podataka postavljena na automatski raspon


Raspodjela relativne vlažnosti na presjeku 2:




Slika 36 Raspodjela relativne vlažnosti na presjeku 2 u trenutku $t = 0$ s




Slika 37 Raspodjela relativne vlažnosti na presjeku 2 u trenutku $t = 300$ s




Slika 38 Raspodjela relativne vlažnosti na presjeku 2 u trenutku $t = 600$ s




Slika 39 Raspodjela tlakova na presjeku 2 u trenutku $t = 960$ s



Slika 40 Raspodjela relativne vlažnosti na presjeku 2 u trenutku $t = 1560$ s



Slika 41 Raspodjela relativne vlažnosti na presjeku 2 u trenutku $t = 1920$ s



Slika 42 Raspodjela relativne vlažnosti na presjeku 2 u trenutku $t = 2400$ s

Napomena: za proučavanje svih prikaza obavezno je referiranje na priloženu skalu, koja je zbog složenosti proračuna i bolje reprezentacije podataka postavljena na automatski raspon

Konačna analiza i prijedlog rješenja

Nakon cijele simulacije, zaključak koji treba donijeti uključuje kako regulirati količinu vlage, shodno tome i grijanje te potencijalno provjetravanje i ventilaciju koji nisu na optimalnim razinama u promatranoj stambenoj jedinici. Vлага koja se generirala, nešto je manje od 1 kg, što i nije neka količina, a značajno naruši stanje atmosfere unutar stambenog objekta. Vidimo kako su i relativne vlažnosti i temperatura na kraju simulacije viši, izlažući se riziku orošavanja po zidovima stambenog prosotra. Stan je pregrijan te u konkretnom slučaju kuhanja ne bi došlo do orošavanja, no da se stan pothladi na temperature za koje je projektiran (sa 26°C na 22°C) orošavanje bi bilo neizbježno i učestalo, sudeći po podacima sa preuzetih mjerača i prema ovoj simulaciji. Ta razlika u temperaturi predstavlja značajan trošak u ekonomsko-energetskom smislu.

Količina vlage ovisi o navikama stanara, temperaturi prostorije te izmjenama zraka u njoj. Kako čovjek sa nizom svojih svakodnevnih radnji generira vlagu, ona negdje mora i otići. Logično rješenje za to jest ventilacija prostora, bilo prirodna u obliku provjetravanja ili prisilna, pomoću dovoda i odvoda zraka (potonje je rijetko korišteno u stambenim zgradama). To provjetravanje efikasna je i potrebna metoda, no često nosi niz problema. Ukoliko je vani vlažno, male se količine vlage zapravo mogu izbaciti, ukoliko su vani padaline prozori se ne mogu prikladno otvoriti za provjetravanje i nepotrebno se gubi više topline, ukoliko je vanjska temperatura niska, javlja se neugoda i veliki gubici topline te možda najbitnije, sve to narušava čovjekov komfor. Rješenje izmjena zraka pomoću provjetravanja kao takvo jest jednosatvno i troši samo onoliko koliko izbaciti toplinu te se tome ne može proturiječiti, no odgovara li to tempu života koji se čovjeku nameće?

Kao prikladno i ekonomski prihvatljivo rješenje ovom problemu nameću se odvlaživači zraka. Oni unutarnji zrak drže na prihvatljivim razinama, mogu raditi automatski te čovjek, osim povremenih čišćenja uređaja nema brige. To jest još jedan uređaj u kući o kojem se ponovno treba brinuti, a zauzima i određenu količinu mjesta. No otvara nove mogućnost, razine komfora i najbitnijeg, zdravlja. Javlja se čak i mogućnosti sušenja odjeće unutar prostorije što je izrazito zanimljivo u zimskim mjesecima, kada jednostavno nema drugog načina.

I simulacija i realno stanje na terenu pokazuju kako unatoč visokim temperaturama prostora (cca 25°C) ova vлага u konkretnom stanu ne predstavlja problem, to jest na granici je problema, ali istovremeno visoka temperatura za sobom nosi veće troškove grijanja. Odvlaživač u tom smislu može pružiti dobru alternativu za lagodniji i u konačnici, jeftiniji život, a sve to bez puno rada stanara na tom uređaju.

Važno je još spomenuti kako i gradnja mora odgovarati projektnim zahtjevima (posebice toplinski mostovi to jest sprečavanje istih) kako ne bi dolazilo do izrazito hladnih zona, koje su u primjeru simulacije na rubu kuhinje, na kutu blagovaonice te pored balkonskih vrata, i bilo kakvo narušavanje sanacije tih toplinskih mostova dovelo bi do garantirane kondenzacije na tim područjima u ovom promatranom simulacijskom modelu.

Zaključak

Numeričkim modeliranjem stanja zraka unutar zatvorenih stambenih prostora može se projektiranje novih zgrada više prilagoditi čovjeku i njegovim aktivnostima. Čovjek u svom stambenom prostoru kuha, tušira se te nerijetko suši odjeću. Sve su to izvori vlage koji u nepovoljnim okolnostima mogu dovesti do narušavanja zdravlja stanara. Vлага se može pojaviti iz razloga nepovoljnih toplinskih uvjeta unutar prostora ili uslijed niskih temperatura okoline u kombinaciji sa lošim odlikama gradnje.

Problem vlage može se svesti na čovjeka ili na projektanta i izvođača. Sav napredak tehnologija i materijala gradnje doveo je do ovog problema, ponajprije zbog rijetke ventilacije samih stambenih prostora, no i zbog ponekad izbjegavanja kompliciranijih i manje ekonomičnih rješenja građevinskih ili termotehničkih problema. Numeričko modeliranje u tom pogledu može pomoći u predviđanjima života unutar budućeg objekta, na način da predvidi nekoliko ekstremnijih situacija u kojima bi se problemi mogli intenzivno pojaviti kao i pregleda uobičajenog načina života stanara, te kako se zgrada ponaša u datim situacijama. Na taj način mogli bi projektanti odlučiti da li treba raditi prilagodbe na termotehničkom ili građevinskom projektu, pazeći pritom na ključne faktore, čovjekovu ugodnost i zdravlje, te ekonomski aspekt projekta.

Termotehnički projekt mogao bi uključiti sustave odvlaživača, napa (za ovu upotrebu nisu podobne recirkulirajuće), ili sustave ventilacija.

Građevinski projekti uključivali bi metode rješavanja toplinskih mostova te implementaciju svih termotehničkih rješenja na adekvatan način.

Treća strana, čovjek, također može sudjelovati u povećanju svoje ugone promjenom nekoliko svojih navika, primarna bi bila ona da prilagodi količinu prirodne ventilacije (prozori i vrata), a od ostalih se nameće pažnja pri izvođenju radnji koje generiraju veće količine vlage, to jest, ponašanje shodno tim radnjama, to jest stanju atmosfere unutar i izvan stambenog prostora.

Implementacija promjena čovjekovih navika polagano bi trebala biti implementirana u proces projektiranja te bi stoga, bar zasad fokus trebao biti usmjeren na optimizacije projekata i buđenje svijesti stanara kako u tim „novim“ zgradama bolje živjeti, u konačnici i zdravije živjeti.

Numerička bi modeliranja pomogla svima uključenima u projekt izrade zgrade, kako bi u konačnosti objekt bio ekonomičniji, a stanar sretniji, i to na način da bi pomoglo u prikazu dinamike buduće zgrade i optimizacije cijele zgrade prema tim podacima.

Valja napomenuti kako bi se u realnom projektu sa svim poznatim parametrima zgrade, točnost ovakvih simulacija bila na razini dovoljnoj za upotrebu u cilju optimizacije projekta stana, etaže ili cijelih zgrada.