

УНИВЕРЗИТЕТ СИНГИДУМУ  
БЕОГРАД  
ОДЕЉЕЊЕ ЗА ПОСТДИПЛОМСКЕ СТУДИЈЕ

ДОКТОРСКА ТЕЗА

Примена вештачке интелигенције за анализу и класификацију стања  
изолације на зградама

МЕНТОР:

Проф. др Марко Танасковић

СТУДЕНТ:

Ивана Валтер, 480110/2020

Београд, 2023. год.

UNIVERSITY OF SINGIDUNUM  
BELGRADE  
DEPARTMENT FOR POSTGRADUATE STUDIES

DOCTORAL THESIS

Application of artificial intelligence to analyse and classify insulation condition  
of buildings

MENTOR:

Professor Marko Tanasković PhD

STUDENT:

Ivana Walter, 480110/2020

Belgrade, 2023

Ментор:

Проф. др Марко Танасковић  
Универзитет Сингидунум, Београд

Чланови комисије:

Проф. др Милош Станковић  
Универзитет Сингидунум, Београд

Доц. др Милан Чабаркапа  
Универзитет у Крагујевцу

## Захвалница

Велику захвалност дугујем мом ментору проф. др Марку Танасковићу, који ме је с пуно подршке пратио у свим корацима мог истраживачког рада и водио рачуна о токовима пројекта. Такође се срдечно захваљујем проф. др Станковићу, који је организовао прикупљање вредних података, који су били основ за развијање принципа вештачке интелигенције у овој дисертацији. Уз њихово велико стрпљење и корисна усмерења у раду на пројекту тезе, стекла сам вредно истраживачко искуство.

Такође бескрајну захвалност дугујем мојој мајци, која ми је пружила пуну подршку у испитивању литературе али и у административним питањима. Важну подршку добила сам и од брата и његових колега са којима сам имала прилику да размењујем идеје, што ми је помогло у практичним имплементацијама програма.

Највеће стрпљење показала је моја породица, која ми је у пружила неизмерну пажњу и која се посебно радује мојој дисертацији.

## Апстракт

Инфрацрвена технологија се изузетно развила, омогућавајући ефикасно и поуздано откривање разних кварова на објектима. Примењује се у многим областима, као што су грађевинарство, електроенергетски системи, машинство и медицина. Инфрацрвена анализа даје слике које репрезентују температурне представе испитиваних објеката. Оне могу открити различите процесе који обично нису видљиви. У грађевинском сектору инфрацрвено снимање омогућава откривање појава у зградама као што су интензиван губитак топлоте, цурење ваздуха и влага, што може указивати на присуство дефеката и потребу да се делује како би се спречила трајна оштећења.

У овом истраживању коришћен је дрон опремљен визуелном и термалном камером за преглед различитих зграда. Комбиноване камере омогућавају паралелну анализу оптичких и инфрацрвених слика из истог угла. Упарени фрејмови из видео тока обе камере су секвенцијално екстраховани и комбиновани да би се открила неадекватна изолација зграда. За разлику од уобичајеног приступа мерења коришћењем стационарних камера, дрони могу ефикасно да сакупе велики број слика једне или више зграда, чак и из углова који су тешко доступни. Поред ефикаснијег процеса мерења, беспилотне летелице пружају висококвалитетне слике на малим удаљеностима са великом резолуцијом и оптималним угловима, који се не могу постићи конвенционалним приступима мерења са земље.

У оквиру овог истраживања, предложени метод комбиновања упарених оптичких и инфрацрвених снимака дрона са обрадом података подржаном вештачком интелигенцијом примењен је на различите пословне и стамбене зграде. Развој машинског учења је омогућио изузетне погодности у многим областима. Овај пројекат користи обучене моделе за детекцију објеката и сегментацију слике, као и алгоритме за препознавање контура и откривање сличности на оквирима. Температуре на инфрацрвеној слици су представљене температурном скалом означеном бојом. Скала у комбинацији са сликом је коришћена као улаз за алгоритме вештачке интелигенције. Циљ овог истраживања је био да се аутоматски детектује и квантификује слабост фасаде из видео тока дрона и локализују региони на објектима где може постојати потенцијална потреба за реновирањем. У првом кораку примењена је сегментација на термалну слику. У другом кораку, фасадне конструкције, прозори и врата су аутоматски идентификовани и издвојени у сегменте уз помоћ оптичке слике. Елементи су затим појединачно обрађени и упоређени да би се издвојила њихова просечна температура, проценили губици топлоте и идентификовала потенцијална подручја са слабом изолацијом. Овај метод обезбеђује целокупну анализу делова грађевинског објекта, извештај о појединачним процењеним температурама и идентификацију оних сегмената на којима су изражени термални губици.

## **Abstract**

Infrared technology has developed enormously, enabling efficient and reliable detection of various defects on objects. It is applied in many fields, such as medicine, mechanical engineering, power systems and construction. Infrared analysis provides images that are temperature representations of examined objects. They can reveal different processes that are normally not visible. In the construction sector infrared imaging allows detecting phenomena in buildings such as intense heat loss, air leakage and moisture which may indicate the presence of defects and the need to act to prevent permanent damages.

In this research a drone equipped with a visual and a thermal camera was used to inspect different buildings. The combined cameras allow parallel analysis of optical and infrared images from the same angle. Paired frames from the video stream of both cameras were sequentially extracted and combined to detect inadequate insulation of buildings. Unlike the usual measurement approach by using stationary cameras, drones can collect efficiently a large number of pictures of one or several buildings, even from angles, which are difficult to reach. In addition to the more efficient measurement process, drones provide high-quality short distance images with large resolution and optimal angles, that cannot be reached by conventional measurement approaches from the ground.

In the scope of this research, the proposed method combining paired optical and infrared drone images with artificial intelligence supported data processing was applied to different commercial and residential buildings. The machine learning development has enabled exceptional opportunities in many areas. This project makes use of trained models for object detection and image segmentation as well as algorithms for contour recognition and detecting similarities on frames. The temperatures in a infrared image are represented by a color coded temperature scale. The scale in combination with the image was used as input for the artificial intelligence algorithms. The aim in this research was to automatically detect and quantify facade weakness from a drone video stream and localize regions on objects, where a potential need for renovation may exist. In a first step, facade structures, windows and doors were automatically identified and cut in segments with the aid of the optical image. In a second step the segmentation was applied to the thermal image. The elements were then individually processed further and compared to extract their average temperature and temperature, estimate heat losses and identify potential areas with weak insulation. This method enables overall analysis of structure parts, estimated particular temperatures and the identification of the segments with intensive thermal losses.

## СКРАЋЕНИЦЕ

PCM	Phase Change Material
GAN	Generative Adversarial Network
BIM	Building Information Modeling
GPU	Graphical Processing Units
CNN	Convolutional Neural Network
R-CNN	Region-based Convolutional Neural Network
RPN	Region Proposal Network
ANN	Artificial Neural Network
ROI	Region of Interest
RGB	Red Green Blue
SfM	Structure from Motion
FPN	Feature Pyramidal Network
MVC	Multi View Stereo
GIS	Geographic Information System
GPR	Ground Penetrating Radar
QIRT	Quantitative Infrared Thermography
SSWD	Street Scenes Window Detection
SIFT	Scale Invariant Feature Transform
SURF	Speed up Robust Features
RFAE	Rough Features Along Edges
BRISK	Binary Robust Invariant Scalable Keypoints
SRRGAN	Super Resolution Reconstruction Generative Adversarial Network

## СЛИКЕ

Слика 1 Итерације алгорита за класификацију зграда .....	17
Слика 2 Шематски приказ Mask R-CNN .....	18
Слика 3 FPN RetinaNet модела .....	20
Слика 4 CNN мрежа.....	21
Слика 5 Визуелни приказ принципа конволуционе мреже .....	22
Слика 6 Средња просечна прецизност при тренирању модела (a) сетом података Window Detection in Street Scenes, (b) генерисаним сетом података [145] .....	28
Слика 7 Принцип Hough трансформације: (a) представа слике у (x,y) равни, (б) трансформација линија у (a, b) равни .....	32
Слика 8 Детектоване линије објекта.....	32
Слика 9 Издвојени снимак који је направљен директно ка објекту .....	33
Слика 10 Адаптирање резолуције визуелних и термалних фрејмова.....	34
Слика 11 Сегментација визуелног фрејма.....	35
Слика 12 Издвојена позадина .....	36
Слика 13 Детектовани прозори моделом тренираним помоћу генерисаног сета података .....	37
Слика 14 Детектовани прозори моделом тренираним помоћу Window Detection in Street Scenes сета података .....	38
Слика 15 Издвојени кров.....	43
Слика 16 Издвојени део фасаде .....	48
Слика 17 Издвојени прозори и корекције ради побољшања тачности прорачуна .....	49
Слика 18 Детектовани и издвојени прозори зграде.....	50
Слика 19 Детектовани термални мостови [145] .....	51
Слика 20 Детектовани прозори и издвојена позадина за зграду .....	52
Слика 21 Сегмент зграде .....	54
Слика 22 Издвојени мањи објекат са детектована три прозора и врата.....	56
Слика 23 Ефекат емисивности.....	60
Слика 24 Поновљена термална мерења за зграде од различитих материјала.....	63
Слика 25 Шематски приказ GAN за поређење термалних слика [124].....	65
Слика 26 Операција преклапања и кластеризовања инфрацрвених слика објеката .....	66
Слика 27 Вероватноћа подударана узорака [124] .....	67
Слика 28 Гаусова дистрибуција температуре .....	68
Слика 29 Варијација радијативне енергије за сукцесивне снимке објекта [145] .....	69
Слика 30 Ефекат угла снимања .....	70
Слика 31 Шематска представа за IoT комуникацију.....	73



## СПИСАК ТАБЕЛА

Табела 1 Техничке карактеристике камера беспилотне летелице .....	26
Табела 2 Издвојени подаци за области грађевине .....	45
Табела 3 Измерене температуре елемената зграде и њихова разлика.....	50
Табела 4 Најчешће боје сегмената .....	53
Табела 5 Процењене температуре појединачних сегмената, пронађене нијансе са инфрацрвених слика и разлика температура за суседне елементе .....	53
Табела 6 Најзаступљеније боје за појединачне компоненте зграде.....	55
Табела 7 Прорачунате температуре елемената, нијансе компоненте и разлика температура .....	55
Табела 8 Измерена радијативна и рефлектована енергија за различите материјале и енергија из атмосфере .....	61
Табела 9 Измерене вредности радијативне, рефлектоване енергије за фасаду од метала, пластике и цигле и енергија из атмосфере .....	62

Садржај	
Захвалница .....	i
Abstract.....	iii
СКРАЋЕНИЦЕ.....	iv
SRRGAN Super Resolution Reconstruction Generative Adversarial Network .....	iv
<b>ПОГЛАВЉЕ 1.....</b>	<b>1</b>
<b>1.1 Увод.....</b>	<b>1</b>
<b>1.2 Циљ истраживања .....</b>	<b>2</b>
<b>1.3 Преглед постојеће литературе .....</b>	<b>5</b>
<b>1.4 Мерења у термографији.....</b>	<b>10</b>
<b>1.5 Примена вештачке интелигенције у обради података .....</b>	<b>14</b>
<b>ПОГЛАВЉЕ 2.....</b>	<b>16</b>
<b>2.1 Примењени алгоритми за обраду инфрацрвених снимака.....</b>	<b>16</b>
<b>2.2 Mask R-CNN .....</b>	<b>17</b>
<b>2.3 RetinaNet.....</b>	<b>18</b>
<b>2.4 CNN.....</b>	<b>20</b>
<b>2.5 GAN.....</b>	<b>23</b>
<b>2.6 K-Means .....</b>	<b>23</b>
<b>ПОГЛАВЉЕ 3.....</b>	<b>25</b>
<b>3.1 Дизајн система за класификацију енергетске ефикасности зграда .....</b>	<b>25</b>
<b>3.2 Сет података и тренирање модела.....</b>	<b>25</b>
<b>3.3 Алгоритми за иницијалну обраду снимака.....</b>	<b>29</b>
<b>3.3.1 Груписање фрејмова са истим објектом .....</b>	<b>30</b>
<b>3.3.2 Селекција перспективе користећи Canny метод и HoughLines детектор .....</b>	<b>31</b>
<b>3.3.3 Алгоритам за подударање визуелних и инфрацрвених снимака .....</b>	<b>33</b>
<b>3.3.4 Сегментација слике за испитивање зграде.....</b>	<b>35</b>
<b>3.3.5 Детекција објеката за издвајање индивидуалних делова .....</b>	<b>36</b>
<b>3.3.6 Детекција термалних мостова на фасади зграде .....</b>	<b>39</b>
<b>3.3.7 Процена температуре за индивидуалне сегменте.....</b>	<b>40</b>
<b>3.3.8 Поређење термалних губитака између елемената зграде .....</b>	<b>41</b>
<b>3.4 Локализација незадовољавајуће изолације на зградама .....</b>	<b>42</b>
<b>3.4.1 Девијација губитака топлоте између прозора и фасаде .....</b>	<b>42</b>

3.4.2	Девијација губитака топлоте између врата и фасаде .....	42
3.4.3	Испитивање изолације већих елемената .....	43
3.5	Значај детектованих губитака за индивидуалне сегменте .....	43
3.6	Укупна анализа зграде .....	44
3.7	Класификација објеката .....	44
3.8	Грешка .....	46
<b>ПОГЛАВЉЕ 4</b> .....		<b>48</b>
4.1	Експериментални резултати .....	48
<b>ПОГЛАВЉЕ 5</b> .....		<b>58</b>
5.1	Поузданост дијагнозе термалних губитака .....	58
5.2	Утицај временских фактора на мерења .....	58
5.3	Утицај материјала зграде на мерења .....	59
5.4	Утицај спољних фактора на мерење .....	68
<b>ПОГЛАВЉЕ 6</b> .....		<b>71</b>
6.1	Поређење са другим техникама .....	71
6.2	Будући трендови .....	71
<b>ЗАКЉУЧАК</b> .....		<b>74</b>
Референце .....		77

# ПОГЛАВЉЕ 1

## 1.1 Увод

У ери рапидног технолошког развоја када су очување енергије и енергетска ефикасност постали императив, вештачка интелигенција заузима важну позицију у широком корпусу области укључених у проучавање и решавање овог комплексног проблема.

Висока енергетска потрошња присутна је у већини земаља света, а очување енергије је један од основних приоритета блиске будућности. Снабдевање енергијом је неопходно за саобраћај, грејање и индустрију и мора бити обезбеђено, што утиче на повећану производњу штетних гасова. Развој у овој области усмерен је ка производњи енергије која је неутрална за емисију гасова и ка трансформацији у обновљиве изворе енергије.

Због све присутније енергетске кризе, актуелан проблем данашњице постао је очување енергије и ресурса. У тежњи да се произведе знатно већа количина енергије, значајан напор улаже се у различитим подручјима као што су дигитализација у контексту снабдевања енергије и развој обновљивих извора енергије, као што су геотермална енергија и биомаса и развој извора као што су енергија ветра и соларна енергија. Будући трендови снабдевања енергије, заснивају се на идеји да се области као што су енергетика, грејање, индустрија, саобраћај, трговина и др. повежу помоћу апликација информационах технологија, како би се енергија трошила на обновљив начин. Настоји се да се омогући да се у интервалима снажног ветра и сунца користи произведена електрична енергија за топлоту или за саобраћај или да се енергија сачува. Поред развијања алтернативних и обновљивих извора енергије, неопходно је развити и стратегије за редуковање потрошње енергије.

Услед глобалног загревања, емисије штетних гасова и већ експлоатисаних природних ресурса енергије, неопходно је континуирано очување енергије. У решавању овог проблема, крупан допринос пружа област вештачке интелигенције, између осталог настојањем да се нађу решења за изградњу општег система за ефикасно испитивање грађевинских објеката, јер је термална ефикасност зграда фундаментални предуслов за уштеду енергије. Представљени метод омогућава поједностављену и брзу детекцију неадекватне изолације и топлотних губитака на различитим објектима помоћу тренираних модела за обраду слика и омогућава аутоматско категорисање грађевинских објеката према стању њихове изолације.

Ова дисертација је организована у седам целина.

У **првом поглављу** наводе се актуелни аспекти у тежњи за уштедом енергије и дати су разлози за испитивање проблема. Изнети су основни принципи класичних термографских мерења, примена вештачке интелигенције и дат је исцрпан преглед постојеће литературе из овог домена уз осврт на уочена ограничења у класификацији изолације зграда.

**Друго поглавље** описује архитектуре модела вештачке интелигенције који је примењен у обради прикупљених података.

У **трећем поглављу** презентоване су методе компјутерске визије у обради снимака као и поступак класификације изолације зграда.

У **четвртном поглављу** дати су резултати мерења термалних карактеристика испитаних грађевина, а у **петом поглављу** анализира се поузданост термалних мерења.

У **шестом поглављу** компариран је у овом истраживању примењен приступ са другим приступима и дат је осврт на будуће трендове у овој области.

У **закључку** су уз сажет опис истраживачког приступа, изнете предности развијеног метода за категоризацију изолације грађевинских објеката.

## 1.2 Циљ истраживања

Зграде представљају велике потрошаче електричне енергије, те је последњих година веома актуелно поље проучавања могућности оптимизације потрошње енергије у зградама. Иновативна решења развијају се у земљама широм света, како би се постигао смањени утрошак енергије, као што су паметни градови који укључују контролисану потрошњу електричне енергије и изградња насеља која су у потпуности снабдевена, ради смањења потребе за превозним средствима. Предлаже се и употреба РСМ материјала у изградњи (Phase Change Material) који могу динамично контролисати примање и отпуштање топлоте [1], као и карбон наноматеријала који чувају енергију [2].

У многим европским земљама зграде представљају значајне потрошаче енергије и према истраживањима на загревање и хлађење зграда троши се око 40% укупне произведене енергије [3]. Новија настојања су оријентисана ка увођењу обновљивих извора енергије у грађевинском сектору. Међутим, не само привредно, већ и еколошки знатно је ефективније смањити потребу за потрошњом енергије на већ постојећим грађевинским објектима.

У том погледу важан аспект очувања енергије односи се на трајност и отпорност компонената зграда, чије је стање потребно пратити, како би се планирала побољшања њихове енергетске ефикасности. Од изолације грађевинских објеката зависе топлотни губици њихових компонената па самим тим и потрошња

енергије која се користи за грејање и хлађење зграда. Делотворност изолације условљена је климатским условима, као и грађевинским материјалима изолације. У току зиме значајан је утрошак енергије за загревање простора, а у летњем периоду коришћење енергије је неопходно за хлађење просторија. Деградација фасада зграда, као што су цурење ваздуха и присуство влаге важан су чинилац нерационалне потрошње енергије, а могу да проузрокују штету и за окружење.

На бази испитивања стања изолације зграда могу се планирати интервенције у случају значајних губитака топлоте, чиме се значајно може редуковати потрошња енергије. У циљу смањења потрошње енергије конципирана је методологија која примењује бесконтактна мерења, обезбеђујући значајне налазе у погледу стања зграде и потенцијалне потребе за реновирањем.

За старије грађевине, за које операције везане за инспекцију и реновирање могу бити ризичне, неопходна је анализа инфраструктуре како би се избегла њихова значајнија оштећења. Додуше неки старији грађевински објекти су конструисани од класичних материјала као што су камен и опека и уколико су им зидови масивни њихова изолација може бити задовољавајућа. Новије зграде су уобичајено конструисане од тањих материјала, као што су бетон и стакло, због чега долази до губитака топлоте, те је потребно да се обави инсталација термичке изолације.

За испитивање зграда већ дуги низ година користе се уобичајено теренски термографски снимци. Мануелно прикупљени инфрацрвени снимци нису подесни за ефикасну термалну анализу већег броја зграда за кратко време. Класичним теренским техникама се ипак не могу испитати тешко доступни делови великих грађевинских објеката, тако да уобичајене инспекције могу бити временски и финансијски неефикасне и неисплативе. У пракси идентификација деградације фасада грађевина још увек преваходно зависи од експертског знања. Анализа великог броја зграда у урбаним срединама представља крупан изазов, те се појавила потреба за развијањем стратегија за убрзану идентификацију оштећене изолације грађевинских објеката, с циљем да се омогући ефикасно локализовање објеката за које је потребна санација изолације или појединих сегмента, као што су прозори, врата и сама фасада. Употребом дрона детектују се топлотни губици и могу се идентификовати недостаци на фасадама зграда.

У данашње време беспилотне летелице се све више користе за инспекцију фасада зграда, јер омогућавају брзо прибављање великог броја слика квалитетне резолуције. Беспилотне летелице могу бити опремљене камерама високе резолуције, инфрацрвеним сензорима, ласерима и другим типовима сензора, тако да је могуће сакупити различите типове података за фасаде зграда [4]. Компликовано и захтевно сакупљање података и анализа грађевинских комплекса носи ризик недоследности и грешака у поновљеним операцијама. Беспилотна летелица пружа могућност прикупљања релевантних података, који се помоћу вештачке интелигенције могу ефикасно обрадити. Преглед појединачних прикупљених термалних слика је временски захтеван напор и захваљујући вештачкој интелигенцији могуће је убрзати процес анализе термалних слика.

Будући да беспилотне летелице обезбеђују снимање различитих објеката у оквиру шире области, у кратком временском року се може прикупити велики број података. Ипак, анализа и интерпретација генерисаних података може бити комплексна. Савремене методе из домена дубоког учења имају велики потенцијал у интерпретацији визуелних података. Стога су мотивисани напори усмерени на примену метода дубоког учења у процесирању података остварених недеструктивном анализом. У овом истраживању настоји се да се анализа велике количине података прикупљених инфрацрвеним мерењима поједностави и аутоматизује, користећи алгоритме вештачке интелигенције и дубоког учења.

Реновирање и обнова стамбених и пословних објеката са слабом функционалношћу изолације и оштећеном фасадом захтева издатке. Како би се утврдило присуство недовољно изолованих региона, развијен је метод који користи недеструктивну анализу мерењем инфрацрвене радијације и евалуацију помоћу метода детекције са надгледањем. Поље дубоког машинског учења донело је значајан напредак у обради слика. Овим методом је омогућена анализа појединачних елемената, па се кроз такав приступ на јасан начин издвајају термалне карактеристике сегмената зграде.

Најзаступљенији губици топлоте су недовољно изоловани прозори и систематски термални мостови који се понављају по површини фасаде. Према емпиријској грађи инспекција обухвата прикупљање и процесирање информација за дијагнозу и интерпретацију резултата. У овој студији развијена је метода за детекцију, дијагнозу и класификацију зграда према термалним губицима како би се омогућила брза идентификација и процена губитака енергије.

Инфрацрвене слике омогућавају локализацију губитака топлоте услед цурења ваздуха, присуства течности као и различитих дефеката на објектима. Поред цурења ваздуха, термални мостови се могу појавити због различитих термалних кондуктивности материјала или због геометријских карактеристика грађевине.

У истраживању су примењени савремени алгоритми вештачке интелигенције, који обухватају методе надгледаног учења и механизме кластеризација, чиме је омогућена убрзана обрада великог броја визуелних података и карактеризација објеката према топлотним губицима. Методе надгледаног учења базирају се на примени означених сетова података за тренирање неуралне мреже, са циљем да се препознају различите категорије објеката. Алгоритми машинског учења захтевају свеобухватне сетове података, како би се постигла идентификација појединачних облика са довољном тачношћу. За ефективност модела вештачке интелигенције била је неопходна одговарајућа припрема податка за тренинг. Због ограничења доступних сетова података генерисан је и нови сет података, што је омогућило високу прецизност локализације сегмената на грађевинским конструкцијама.

Generative Adversarial Network (GAN) се примењује у обради термографских слика да би се побољшала видљивост дефеката. Способност ове мреже је искоришћена за процену температурних варијација у вишеструким, противречним термографским мерењима истих објеката.

Мада су се у протеклих неколико година појавила бројна истраживања у области инспекције фасада зграда помоћу беспилотне летелице уз коришћење алгоритама вештачке интелигенције у обради података, они се ипак углавном односе на генерисање 3D модела за инфрацрвени приказ зграда, на детекцију пукотина и оштећења фасада помоћу великих означених сетова података, као и на испитивање унутрашњег простора. Дакле, није развијена методологија која се може применити на инспекцију произвољних грађевина како би се категорисала њихова енергетска ефикасност. Претходне студије се пре свега односе на детектовање специфичних типова аномалија. Иако се у литератури помиње свеобухватна примена вештачке интелигенције и термографије у стратегијама за одржавање објеката, ипак постоји недостатак практичних метода које би побољшале идентификацију недостатака у сфери енергетске ефикасности објеката.

Због захтевне анализе добијених сетова података, у овој дисертацији је развијен другачији приступ базиран на дубоком учењу, ради постизања аутоматизације овог процеса. Вештачка интелигенција је употребљена као кључни алат за аутоматско откривање елемената конструкције. Добијени резултати омогућили су да се одреде критеријуми за утврђивање недостатака у свеукупној изолацији.

Представљен је метод којим се ефикасно анализирају топлотни губици на различитим деловима објеката као што су прозори, врата и сама фасада и који указује на површине са значајним топлотним аутоматским путем. Предност овог принципа је да се за многе различите грађевинске објекте могу детаљно анализирати све компоненте и у томе што се даје комплетан извештај термалног понашања објекта. Анализа објеката путем алгоритама дубоког учења омогућава циљану обраду слика и симултано процесирање паралелних термалних и оптичких секвенци. Овакав приступ значајно може да поједностави процес у дијагностици квалитета и трајности изолације зграде.

Захваљујући ефективном принципу мерења и анализе података путем машинског учења, ова методологија је применљива за испитивање насеља и за обраду велике количине података, са циљем да се уоче они објекти за које је неопходно адаптирати изолацију.

### **1.3 Преглед постојеће литературе**

Из приказа постојеће литературе уочава се да су заступљени различити приступи у термографском испитивању зграда, али се у већини радова оперише подацима о парцијалним аспектима проблема везаним за енергетске губитке грађевинских објеката.

Приступу у којима се користи беспилотна летелица опремљена визуелном и термалном камером обезбеђују јединствен извор информација за испитивање фасада зграда на ефикасан и тачан начин, из простог разлога што беспилотна



летелица омогућава да се добију висококвалитетни подаци из свих перспектива, а могуће је и понављање експеримената. У [5] истраживачи су најпре извршили макроинспекцију зграда за детектовање термалних аномалија, а затим и микроинспекцију за класификацију значаја детектованих аномалија. Они су препоручили да удаљеност беспилотне летелице буде од 3 до 10 m и поред тога истичу значај одржавања угла снимања нормално у односу на површину зграда, као и избегавање заклањања делова зграда суседним објектима. Они су пре свега настојали да се помоћу алгоритама дубоког учења детектују пукотине и оштећења. Њихов приступ у класификовању недостатака, као што су цурење ваздуха, оштећења и присуство влажности, захтевао је много времена и ангажман специјалиста у анализи података. Употребом хистограма који представља динамичку дистрибуцију вредности пиксела, прорачунате су за сваку слику две вредности прага. Један праг је дефинисан код опадања вредности пиксела, под претпоставком да је пронађена аномалија. Други праг је означавао јаке репрезентације пиксела, а употребили су га да би се прерачунао хистограм. Дуж ивица које су пронађене користећи Canny Edge детектор, обрадили су сваки пиксел поредећи суседне вредности према добијеним праговима, да би извршили предикцију региона са губицима.

Према ауторима [6] приликом термографских мерења беспилотном летелицом, велике дистанце и оштри углови снимања утичу на смањени квалитет инфрацрвених слика, док брзине лета немају негативни утицај на њихов квалитет. Они су употребили обновљену верзију сета података “Thermal Bridges on Building Rooftops” у којој су обухваћени комбиновани визуелни и термални снимци са подацима о висини. У овом сету података видљиви су и околни објекти. Користили су доступне моделе за обраду слика Facebook AI Research’s Detectron 2 и OpenMMLabs MMDetectron за локализацију термалних мостова на крововима. Тренирајући их помоћу различитих архитектура упоређивали су резултате.

Свеобухватни преглед примене беспилотне летелице и изазова у сакупљању података, као и софтвера који се примењују у обради снимака, представљен је у [7]. Због високе способности презентовања својстава слика и великог успеха у њиховој класификацији и препознавању циља, конволуциона неурална мрежа CNN се учестало примењује приликом прикупљања података беспилотном летелицом и предложена је за откривање оштећења на површинама зграда и мостова.

Мрежа Cross View Matching је развијена за уочавање локалних својстава објеката да би се дескриптори глобално представили. У широкој употреби је и реконструкција односно триангулација позиција камера за 3D сцене из 2D слика, што је једна од базичних функција у фотограметрији и компјутерској визији. У новије време структура из покрета (Structure from Motion, SfM), донела је могућност да се преко покрета камере и калибрационих параметара реконструише геометрија сцене, за шта је неопходно прецизно подударање својстава слике. У неколико истраживања предлаже се прикупљање података беспилотном летелицом уз примену фотограметријских тродимензионалних метода за реконструкцију и анализу слика у препознавању аномалија. 3D реконструкција обухвата мапирање текстура из учесталих сцена при померању камере, како би се добила структура

објекта упоређујући слике, што представља Multi View Stereo Matching. У [8] прикупљене термалне информације помоћу беспилотне летелице биле су уклопљене у 3D структуру, користећи RGB слике значајно бољег квалитета од оних прибављених уз помоћ термалне камере. Процес креирања 3D модела заснива се на идентификацији истих тачака на више слика и области добијених из различитих позиција камере. Ови аутори су за добијање термалне представе спољашњости зграде употребили термалне слике за текстуру уз уклапање позиција термалних и RGB слика.

У истраживању [9] које обухвата Internet of Things (IoT) експедицијом беспилотне летелице, представљене су технике машинског учења у тумачењу слика. Ефектност дрона у термографској анализи зграда проучена је и у [10] студији, која укључују 3D моделе SfM и MVC (Multi View Stereo) технике за реконструкцију зграде.

Истраживачи у [11] баве се интеграцијом информативних модела зграда и инфрацрвене технологије и комбинују информације за аутоматско генерисање 3D модела зграда фузијом података са различитих платформи.

Према ауторима [12] применом инфрацрвене термографије могу се диференцирати различити конструкцијски материјали, употребљени за изградњу зида. Они су обавили термална мерења за различите температуре у унутрашњости и спољашњости зграде у различитим данима да би утврдили разлику у термалној индуктивности. Користећи ненадгледану класификацију са KMeans методом издвојили су карактеристике материјала.

На снимцима добијеним беспилотном летелицом могу се детектовати пукотине и губици топлоте, што је применом Sobel, Laplacian и Canny алгоритма испитано у [13].

У [14] узет је за параметар деградације однос деградиране и референтне површине фасаде и утврђена је квалитативна скала за визуелну и физичку оштећеност фасаде.

Према ауторима из [15] применом инфрацрвене и Ground Penetrating Radars (GPR) технике за аудит зграда, могу се локализовати оштећења и може се утврдити степен захваћености. Они су препоручили снимање објекта на одстојању од 1 m и вредност емисивности 1, будући да су зидови конструисани од различитих материјала, па су спровели некомпензована мерења привидне температуре. GPR метода се уобичајено користи за детекцију скривених структура и за процену квалитета материјала.

У истраживању [16] комбинованом применом ултразвука и термографије откривене су велике концентрације влаге, које нису уочљиве визуелним прегледом. Приликом инспекције цркве из прошлог века помоћу термографије локализоване су области са значајним оштећењима услед присуства влаге и утврђени су различити материјали. Ултразвук је омогућио детекцију степена пропадања материјала и локализацију цурења.

Научни сарадници су у свом прегледном раду [17] указали на различите примене алгоритама заснованих на надгледаном учењу и истакли напредне перформансе остварене на основу означених података, за разлику од несупервизованих метода које су имале слабију тачност. Они су дали детаљан преглед примене вештачке интелигенције у обради података, као што су функционални подаци о згради и мерења помоћу паметних сензора за предвиђање енергије, детекцију аномалија и локализацију влаге.

Аутори су у [18] приликом мерења повећавали растојање до објекта, што је доводило до промена температуре. Са различитих локација, они су прикупили податке путем теренске анализе фасаде зграде и унутрашњег зида објекта. Предложили су модел за компензацију температуре, због грешке која настаје мерењима температуре проузрокованим промењеним растојањем.

У прегледном раду [19] представљени су резултати QIRT и ултрасоничног тестирања са фокусом на студије које су извођене на старијим зградама.

У [20] изложене су предности примене вештачке интелигенције у грађевинарству почевши од архитектонских модела до напредне изградње. Променљивост измерених температура уз површине грађевине захтева разматрање фактора везаних за услове околине.

Применом термографије и беспилотне летелице у [21] пронађене су температуре разматрањем емисивности фасаде и прорачуном термалне радијације. Приликом инспекције двоспратне зграде са стакленим областима, измерене су унутрашње и спољашње температуре и праћењем температурних разлика, утврђено је да ли је било потребно подесити емисивност.

Употребом инфрацрвеног мерног инструмента, може се убрзано добити температурна дистрибуција фасаде зграде, а са инфрацрвених снимака се са тачношћу могу локализовати термалне аномалије. У [22] термографијом су локализоване области термалних дефеката на згради. Упркос униформних температура спољашњости зграде и прозора, уочена су температурна одступања на појединим деловима прозора и значајне температурне промене око оквира врата.

Поновљивост инфрацрвеног мерног уређаја подразумева добијање приближних вредности пиксела из исте перспективе за краће време. Ипак се може догодити да секвенцијални термални снимци покажу значајније температурне варијације што се односи на прецизност инструмента. Аутори су у [23] развили алгоритам за филтрирање неодговарајућих слика помоћу емпиријски добијених вредности прага. Са циљем да генеришу прецизне 3D мапе испитивањима у унутрашњим просторима, они су креирали простор тачака, где је свакој од њих асоцирана RGB боја и температура. За прорачун стварне вредности температуре, они су проценили трансмитансу узимајући у обзир емисивност испитиваног материјала и рефлектовану радијативну енергију. На зидове унутрашњости објекта аутори су поставили електричне траке и савијене алуминијумске фолије, да би направили корекције услед рефлексије и да би прорачунали коректну емисивност објекта. Привидну рефлектовану температуру утврдили су са визуелних слика применом

филтера високе фреквенције, чиме се постиже значајно приметна разлика у интензитету. При том су претпоставили да је привидна рефлектована температура једнака температури алуминијума. Емисивност објекта добили су мерећи температуру термалном камером у близини објекта. Прорачуном температуре објекта, добијене су вредности трансмитансе на зидовима и оквирима прозора и врата.

Разне технике које се заснивају на вештачкој интелигенцији примењују се у предвиђању утрошка енергије зграда, а једна од најзаступљенијих метода је ANN (Artificial Neural Network) која представља математички модел за обраду информација према узору на биолошки нервни систем. У студији [24] побољшана изолација била је утврђена користећи инфрацрвену технику, а ANN је била употребљена да би се предвидела термална ефикасност зграде и очекивана уштеда енергије користећи историјске податке. Из задатих података тренирана је мрежа како би се искористили познати параметри у обради нових улазних величина, захваљујући способности мреже да повеже комплексне релације између улазних и излазних величина. Утросак енергије је био предвиђен на основу примера модерне зграде, да би се уштеда енергије упоредила после унапређења структуре објекта.

Значајан допринос у класификацији и сегментацији постиже се методама дубоког учења, а перформансе модела се пореде користећи параметар просечне прецизности и просечну IoU вредност (Intersection over Union). Према ауторима [25] значајан део сирових термограма садржи поновљене информације па су стога користили само почетне фрејмове из података прикупљених за тренинг. Они су добили нови сет података након 19 мерења користећи 19 узорака, на основу којих су видљиве дефекте у сету података уочили и употребили су различите моделе за сегментацију кварова оригиналног сета података. Након експеримената импулсне термографије уз примену спољњег извора топлотне енергије и инфрацрвене камере мерили су процес хлађења површине објеката и применили су различите моделе дубоког учења, укључујући U-Net и SegNet са VGG мрежом. Према њиховим резултатима мрежа U-Net VGG11 показала се као најефективнија. За идентификацију кварова у композитним материјалима, тренирали су Faster-RCNN, а за класификацију оштећених и здравих области искористили су Support Vector Machine технику.

У [26] анализирани су детектоване аномалије на грађевини користећи беспилотну летелицу и стандардну инфрацрвену камеру и интерпретиране су температурне расподеле користећи добијене термограме.

Као што се наводи у студији [27] многе недеструктивне методе и механизми су тренутно доступни за испитивање коришћења енергије у зградама, укључујући мерења топлотног флукса, тестове грејања, аутоматско читавање, тестове ваздуха и симулацију прорачуна, који се односе на специфична енергетска својства зграда.

## 1.4 Мерења у термографији

Термографија омогућава визуализацију топлотних процеса на објектима и може се употребити као удаљена техника за различита испитивања у индустрији, детекцији гаса и ватре, као и за праћење покретних објеката. Термографијом се могу утврдити патолошке промене у структурама праћењем температурних разлика.

Термографија је методологија којом се прикупљају и процесирају термалне информације употребом бесконтактних мерних уређаја. На овај начин се детектује емитована инфрацрвена енергија са објеката, која се затим конвертује у електричне сигнале, који омогућавају креирање термалне слике. На тај начин се добија детаљна визуелна слика температурног профила која представља дистрибуцију топлоте материјала. Термографија омогућава ефикасну идентификацију губитака енергије и указује на критичне регионе грађевине који се на тај начин могу правовремено обновити и адаптирати.

Температура представља функционално стање објеката које карактерише термодинамички баланс система. Између два тела различитих температура постоји ток енергије од топлијег ка хладнијем телу услед тежње да се температура изједначи. Сви објекти чија је температура виша од 0К емитују радијативну енергију. Стога интензитет емитоване радијације расте са порастом температуре.

Три физичка механизма одликују преношење топлоте: кондукција, конвекција и радијација. Кондукција представља пролазак топлоте на физичком контакту између два објекта и на зградама се одвија кроз зидове изнутра ка споља уколико је унутрашња температура зграде виша од спољашње температуре. У супротном уколико је спољна температура виша од унутрашње температуре, процес преношења топлотне енергије је споља ка унутра. Према другом закону термодинамике, топлота увек тече из топлије ка хладнијој области и овај процес се одвија у току хладне сезоне када је зграда загревана, што је повољно време за инспекцију изолационих способности грађевине.

Како се ваздушна маса помера од топлијих ка хладнијим областима, унутрашња температура уобичајено није једнака на свим нивоима зграде. Измерена температура на спољашњости зграде зависи не само од квалитета изолације, већ и од загревања унутрашњости простора. Уобичајено су у одређеним регионима зграде температуре ниже него у другим деловима, нпр. на вишим нивоима зграде као што је поткровље, јер најчешће није потребно грејати ове просторије. Услед померања топлотне масе кроз зграду, како топли ваздух достиже хладне површине, може доћи и до кондензације и топлотних губитака ако је недовољна изолација.

Конвективни термални мостови су енергетски губици који се јављају због померања ваздуха унутар зграде. Конвективно померање ваздуха се може догодити уколико постоје пукотине у блоковима зграда или између различитих изолационих слојева. Уколико је присутан јачи ветар у току инфрацрвених мерења, ваздух се може померати по површини зграде у форми конвекције која може ометати

детекцију сигнала на површини, који се у том случају учестало мења. Конвективна петља је процес подизања топлог ваздуха и спуштања хладног ваздуха. Интензивни губици топлоте могу настати и услед директног утицаја спољашњег ваздуха кроз изолацију, што представља трансмисију топлоте.

Радијација се може емитовати са објекта, пренети кроз грађевину са суседних објеката или рефлектовати. Ова зависност је описана следећом једначином и према њој је сума емисије, рефлексије и трансмисије једнака један:

$$\varepsilon + r + \tau = 1 \quad (1)$$

Емисија представља део енергије који се емитује са објекта. Емитована радијација од објекта зависи од емисивности  $\varepsilon$  и од четвртог степена температуре  $T_{ems}$ :

$$E_{ems} = \varepsilon \sigma T_{ems}^4 \quad (2)$$

где  $\sigma$  представља Stefan-Boltzman константу  $\sigma = 5.670374 \cdot 10^{-8} \text{Js}^{-1} \text{m}^{-2} \text{K}^{-4}$ . Емисивност је део радијације који се емитује у поређењу са емитовањем црног тела које апсорбује сву радијацију. Емисивност је одлика материјала и може имати вредност у опсегу од 0 до 1. Емисивност је важан фактор за инфрацрвена мерења и директно утиче на мерења инфрацрвеним сензорима.

Рефлексија  $\rho$  представља радијативну енергију која се рефлектује на објекту. Емитована енергија рефлективности зависи од рефлективности објекта и од температуре  $T_{ref}$  која је пропорционална радијацији:

$$E_{ref} = \rho \sigma T_{ref}^4 \quad (3)$$

Трансмисија представља део енергије који пролази кроз објекат. Објекти из окружења зраче одређену енергију и од трансмисивности мереног објекта зависи трансмитована енергија:

$$E_{trs} = \tau \sigma T_{trs}^4 \quad (4)$$

где је  $\tau$  трансмисивност објекта, а  $T_{trs}$  је температура објекта из окружења. Уобичајено се може сматрати да је трансмисивност објекта једнака 0, што значи да се може сматрати да је  $\varepsilon + r = 1$ . Из тог разлога стандардна мерења која су спроведена, укључују прорачун емитоване и рефлектоване енергије.

$$E = \varepsilon \sigma T_{ems}^4 + (1 - \varepsilon) \sigma T_{ref}^4 \quad (5)$$

Услед утицаја атмосфере долази до одређеног губитка енергије због трансмисивности ваздуха, па је измерена радијативна енергија, при чему је трансмисивност атмосфере  $\tau_A$ , а спољна температура  $T_A$ :

$$E_{mer} = \tau_A(\varepsilon\sigma T_{ems}^4 + (1 - \varepsilon)\sigma T_{ref}^4) + (1 - \tau_A)\sigma T_A^4 \quad (6)$$

Приликом мерења је претпостављено да је растојање између мерног инструмента и зграде релативно мало и да се губици услед трансмисије кроз ваздух могу занемарити. Такође је претпостављено да се при облачном времену утицај рефлексије може занемарити за зграде које су од материјала високе емисивности. Ови закључци су потврђени поновљеним детаљним мерењима за различите грађевине и при различитим спољним условима.

Инфрацрвена радијација је електромагнетна радијација са таласним дужинама већим од таласних дужина видљивог светла и због тога се употребљавају инфрацрвени сензори који детектују ову радијацију. Инфрацрвена камера детектује инфрацрвену радијацију у различитим областима електромагнетног спектра. Мерења температуре су извршена коришћењем инфрацрвених сензора беспилотне летелице. Различити извори дају другачије поделе инфрацрвеног спектра. Према [28] инфрацрвена радијација је подељена у следеће области: близак инфрацрвени спектар 0.8-1.7  $\mu\text{m}$ , краткоталасни спектар 1-2.5  $\mu\text{m}$ , средњеталасни спектар 2-5  $\mu\text{m}$ , дуготаласни спектар 8-14  $\mu\text{m}$ . Иако термалне камере заправо мере површинску радијацију, за идентификацију недостатака на грађевинама потребно је читати температурне разлике.

Црно тело апсорбује читаву примљену енергију на свим таласним дужинама која се трансформише у топлоту и поново емитује. Са порастом температуре емитује се више радијације што одговара краћим таласним дужинама. Реални објекти могу достићи карактеристике црног тела на одређеним фреквенцијама.

Различити аспекти који се односе на резолуцију у термографији су спектрална резолуција, просторна резолуција, радиометријска резолуција и темпорална резолуција. Камере које се користе у термалној анализи зграда најчешће спроводе спектралну анализу дугих таласа инфрацрвене радијације (од 8 до 14  $\mu\text{m}$ ) у оквиру електромагнетног спектра. Фактор који диктира просторну резолуцију представља величину детектора где већи број пиксела побољшава просторну резолуцију. Радиометријска резолуција односи се на најмању температурну разлику која може бити детектована камером. Темпорална резолуција представља фреквенцију освежења слике камере. Због значајне практичне примене, широк дијапазон различитих инфрацрвених мерних уређаја постао је доступан, како за професионалну, тако и за приватну употребу, који се могу одабрати према резолуцији, перформансама, опсегу таласних дужина детектоване инфрацрвене светлости, као и фреквенције фрејмова видео записа.

Нивои термалног мерења су одређени максималним и минималним температурама, које су дефинисане температурним опсегом. Опсег одређује

контраст термалних слика, а могу се одабрати различите палете боја, као што су дугина и irgon палета, које су најчешће у употреби. Инфрацрвена камера користи нелинеарне филтере који замућују слику задржавајући ивице и замењују пикселе подешеним просечним вредностима суседних пиксела. Палета мерног инструмента дефинише боје које се користе у колоризацији пиксела псеудобојама.

Термалне слике могу указати на присуство термалних мостова на појединачним сегментима на зиду, проток ваздуха кроз компоненте, као и на влажност, оштећења материјала и корозију. Термални мостови су слабије изоловане области на спољашњим зидовима грађевине, који проузрокују губитке топлоте, прикупљање влаге и појаву буђи у материјалима. Термални мостови се појављују као последица смањене термалне отпорности и убрзаног преноса топлотне енергије из топлијих ка хладнијим областима. Термалне слике дају информације на бази пиксела о емитованој радијацији са различитих површина грађевинског објекта. Области на инфрацрвеним сликама које приказују више површинске температуре указују на лошији квалитет изолације зидова и прозора, као и на могуће протицање ваздуха између спојева елемената грађевине. Мерење инфрацрвеног зрачења кроз ваздух са краће дистанце помоћу термографске камере беспилотне летелице је једноставан и користан начин да се утврди отпорност зграде на термалне губитке. Термографија се такође може употребити како би се испитало транзијентно температурно понашање у току времена.

Позната су два могућа приступа у термографији: пасивна у којој се испитују материјали, који су природно на другачијим температурама и активна у којој се користи спољни стимулус да би се генерисао термални контраст на површини објекта. У представљеној методологији примењена је пасивна термографија без спољних извора топлоте. Такође се разликују статичка термографија, где камера, објекат и извор остају на истом месту у току инспекције и динамичка, где се барем један од ових елемената помера. Иако је статички приступ повољнији за обраду података, ипак се у пракси овом методом не могу једноставно испитати компоненте великих димензија из фиксног положаја. Због тога приступ испитивања зграда у овој студији подразумева динамичку термографију, јер се употребом беспилотне летелице, инфрацрвени мерни инструмент помера. Термална инспекција зграда може се категорисати као квалитативна анализа и квантитативна анализа. Квалитативна анализа се односи на детаљну интерпретацију мерења, што представља скуп и захтеван процес и не пружа скалабилност за градска подручја. Метод заснован на вештачкој интелигенцији представља квантитативни приступ и омогућује аутоматизован и убрзан процес инспекције.

Термографија има важну примену и у детектовању влаге у грађевинама, која може проузроковати штету у материјалима и појаву буђи. Пасивним приступом термографије може се пратити распрострањеност влаге и процес хлађења водене паре. Појава кондензације зависи од влажности ваздуха у непосредној близини површине објекта, од температуре и од структуре материјала. Термографијом се могу пратити слична стања воде која у процесу кондензације прелази из течног стања у водену пару, хладећи површине зидова.



Друге недеструктивне технике користе се за карактеризацију површина и за детекцију оштећења на површинама. Недеструктивне методе могу се поделити у површинске и у волуметријске процесе. Анализа површина материјала спроводи се и употребом ласера, импулсне термографије, X зрака идр. Ултрасонична техника користи звучне таласе којима се могу испитати микроструктуре материјала и утврдити еластичне карактеристике и овај приступ се користи за мерење дебљине матријала и омота, тока материјала и микроструктура.

## 1.5 Примена вештачке интелигенције у обради података

Технике машинског учења су омогућиле да се искористе подаци који су прикупљени у вези са одређеним појмом и препознајући специфичне карактеристике на бази ових података, могу се креирати модели како би се предвидели будући трендови који се односе на дато подручје или како би се препознале специфичне карактеристике за нове податке.

Методе машинског учења обухватају моделе, засноване на надгледаном и на ненадгледаном учењу. Надгледано учење подразумева коришћење означених сетова података. Ненадгледаним учењем се тренира модел из изворних и најчешће неозначених сетова података и процес учења се одвија без претходног знања. Међутим иако не постоји потреба да се означе подаци као у надгледаном учењу, фаза тренирања мреже може захтевати интензивно процесирање, јер се испитују различите могућности. Под семисупервизованим моделима машинског учења приликом тренирања користи се мањи број означених података и велики број неозначених посматрања. Модел треба да са тачношћу изврши предикције за нове податке. Модели класификације могу на основу процеса тренирања и улазних података донети закључке и предвидети категорије за нове сетове података.

Недавни брзи развој чипова и GPU-ова (Graphical Processing Units) омогућио је покретање комплексних алгоритама који могу обрадити велике количине података и на основу тога предати информације од значаја. Појавио се велики број сензора који могу прикупити различите податке, због чега се свакодневно производи и велика количина визуелних података. Компјутерска визија је област истраживања која се бави визуелним подацима. Различите камере које нас окружују пружају информације о свету и дешавањима, а напредак у компјутерској визији омогућава да се компјутерски разумеју визуелне информације и донесу одлуке.

Компјутерска визија има широку примену, као што су детекција објеката, којом се могу класификовати предмети, биљке и животиње, детекција различитих болести и промена у организму у медицини, препознавање различитих објеката на бази пиксела, обрада видео записа у реалном времену у аутономним возилима, као и компјутерско генерисање нових слика помоћу GAN (Generative Adversarial Network).

Варијације конволуционе неуралне мреже (CNN) развијене из инспирације визуелним кортексом, показале су високе перформансе, као што су AlexNet, и ResNet. Алгоритми за обраду слике и видеа, заснивају се на различито структурираним неуралним мрежама и спроводе операције као што су детекција објеката оквиром и семантичка сегментација. Тренирањем модела користећи велики број слика могу се детектовати објекти одређене класе. Приликом процесирања улазне слике, издвајају се карактеристике слике на основу којих неурална мрежа препознаје одређене форме и текстуре, локализује их и класификује. Издвајање својстава је важан процес у детекцији, јер омогућује детекцију објеката прорачунавањем њиховог подударана и упоређивањем њихове зависности, као што је одређивање специфичних позиција објеката. Различити приступи за селекцију карактеристика слике заснивају се на расподели вероватноће карактеристика за различите класе и одређују да ли класификација може бити обављена. Циљ је да се пронађу карактеристике које су дате испитивањем пиксела, локација, карактеристика боја и њиховог односа. Постоји неколико врста карактеристика као што су глобалне, које одговарају регионима на слици, док локалне карактеристике уобичајено представљају границе специфичног облика на региону слике што је важно за препознавање објекта. Релационе карактеристике односе се на растојања и њихову оријентацију. На овај начин релативне позиције предмета су одређене за специфичне објекте и користе се да се провери да ли се одређени објекат појављује на слици. Свака класа објеката се може представити специфичним карактеристикама. Као резултат се добијају оквири око детектованих објеката, њихове координате и класе објеката. Механизми за компјутерски базирану анализу слика могу препознати и недостатке на фасади као што су дефекти, оштећења и изобличења.

Регистрација слика принципијелно представља просторну трансформацију позиционирајући тачке једне слике преко одговарајућих тачака друге слике у циљном координатном систему. Уобичајене методе регистрације за слике са беспилотне летелице обухватају технике *stitching* и мозаика слика засноване на својствима слика. Ове технике обухватају издвајање својстава, подударана својстава, процену модела трансформације и трансформацију слике. Генерално технике мозаика слика обухватају неколико корака: препознавање својстава, компарацију, естимацију трансформационог модела и одабирање и трансформацију слике. Постоје бројни ресурси у оквиру техника компјутерске визије за аутоматско препознавање својстава укључујући детекторе као што су SIFT (Scale Invariant Feature Transform), ASIFT (Affine SIFT), SURF (Speed up Robust Features), RFAE (Rough Features Along Edges) и BRISK (Binary Robust Invariant Scalable Keypoints).

Класификација представља методу машинског учења у којој се предвиђају класе објеката за нове улазне податке, доносећи закључке на основу тренирања модела. Кластеризација је категорија машинског учења за издвајање различитих класа односно сличних инстанци и представља методу ненадгледаног учења. Механизми кластеризације се често користе у детектовању аномалија. Најпознатије методе кластеризације су KMeans, c-means и fuzzy. Лимитације овог приступа су зависност кластера од иницијално дефинисаног броја кластера  $k$  и нескалабилност.

## ПОГЛАВЉЕ 2

Наредних пет поглавља ове дисертације описују детаљан дизајн система за класификацију енергетске отпорности зграда. Значајан део методологије представљене у овим поглављима објављен је у научним часописима.

### 2.1 Примењени алгоритми за обраду инфрацрвених снимака


Из снимака визуелне и термалне камере беспилотне летелице секвенцијално су издвојени паралелни фрејмови, да би се детектовала критична изолација на грађевинама. Помоћу компјутерске визије инфрацрвене и визуелне слике су трансформисане, како би се омогућила анализа зграде. Евалуација енергетске ефикасности зграда заснована је на прорачунима температура.

Пристап при класификацији изолационе способности се у овом пројекту заснива на праћењу топлотних губитака свих области површине зграде, њиховим превођењем у температурне вредности и поређењем топлотних губитака на појединачним елементима. Методом класификације води се рачуна и о томе да ли је сегмент на површини зграде у светлој или у тамној боји, чиме се могу потврдити налази да су процењене температуре више или ниже. У итерацијама алгоритма се утврђује да ли су присутни значајни топлотни губици на прозорима или на фасади према вредностима температура. Одређује се и колика је површина захваћена топлотним губицима. Детектоване више температуре компонената зграда примењеним алгоритмима вештачке интелигенције могу бити резултоване цурењем ваздуха, губицима топлоте или дефектима у изолацији.

Креирани модел укључује неколико различитих алгоритма којима се обрађују слике. Из визуелних и инфрацрвених снимака издвојене су слике како би се спровела анализа зграда. Узете су у обзир слике које из повољног угла представљају грађевину, јер угао снимања има важну улогу при инфрацрвеним мерењима. Помоћу модела дубоког машинског учења уклоњена је позадина са релевантних снимака за анализу, чиме се остварује аутоматска термална анализа зграде. Алгоритмима вештачке интелигенције могу се систематски појединачне компоненте објекта препознати и селектовати ради процене температура. Светле боје на сегментима спољашњости зграда указују на високе топлотне губитке, а насупрот томе тамне нијансе делова зида указују на мањи губитак топлоте. Програм за класификацију грађевинских објеката доноси одлуку о квалитету и отпорности изолације компонената зграда, тако што се процењене температуре упоређују укључујући очекивану грешку. На тај начин се може закључити у којим деловима се јављају већи топлотни губици и због тога се могу сврстати у категорију слабије изолације. Препознавањем топлијих области изван зграде могуће је аутоматски детектовати топлотне мостове који се могу евидентирати на површини фасаде. У

наставку су описани алгоритми који су употребљени у методологији за обраду снимака и класификацију термалне отпорности зграде. Представљене су неуралне мреже примењене у истраживању и детаљно су описане њихове функције и карактеристике.


Наредни дијаграм показује методу која је примењена у овом истраживању. Фазе обраде паралелних снимака беспилотне летелице, укључују различите неуралне мреже засноване на супервизованом учењу. На излазу се обављају операције класификације објеката и њихових компонената и врши се детекција сегмената са топлотним губицима.



Слика 1 Итерације алгоритма за класификацију зграда

## 2.2 Mask R-CNN

Mask R-CNN омогућава сегментацију инстанци која се односи на препознавање различитих објеката и заснива се на систему Faster R-CNN. Шема овог метода је представљена на слици. Улазна слика се пропушта кроз конволуциону неуралну мрежу (CNN) и на излазу се добија мапа својстава. Овај метод уводи засебну мрежу Region Proposal Network (RPN) која генерише регионе од интереса где се највероватније могу наћи објекти, за разлику од претходника Fast R-CNN где се региони од интереса предлажу на основу мапе својстава која се добија након преноса улазне слике кроз CNN. Код првобитног R-CNN метода предложени региони или ROI се генеришу на улазној слици, а затим се сваки регион од интереса ROI преноси кроз CNN ради класификације објекта користећи потпуно повезане слојеве. Потпуно повезани слојеви на крају мреже омогућавају класификацију објеката и генерисање оквира у којима су локализовани објекти. RPN мрежа доноси одлуке да ли су присутни објекти и проналази оквире око њих за сваки регион од интереса прорачунавајући RPN губитке. Сви предложени региони са позитивним прагом у поређењу са тачном базом објекта се даље испитују у мрежи. Региони од интереса имају различите величине и процесирани су у слоју RPN. Поравнањем се издвајају мапе својстава фиксне величине задржавајући ROI. На крају мреже се прорачунавају губици класификације и генерисања оквира како би се постигла боља тачност и означавају се објекти на бази пиксела.



Слика 2 Шематски приказ Mask R-CNN

За сваку ROI мапу својстава на излазу се добија маска која показује који пиксели одговарају објекту на слици. Сегментација слике захтева бинарне маске као ознаке за тренинг. Оне садрже низове са димензијама које одговарају слици. Међутим, уместо RGB вредности пиксела оне садрже 0 и 1 које представљају вредности где се објекат на слици налази.

Прорачуни за анализу површине зграде омогућени су уклањањем позадине суседних објеката. Библиотека Pixellib у Python-у садржи претходно трениране моделе помоћу великог скупа података који могу да сегментују слике и да на бази пиксела издвоје објекте помоћу карактеристичних боја. Алгоритамским уклањањем специфичних боја које представљају небо и дрвеће, добија се одговарајућа маска која се затим примењује на паралелну инфрацрвену слику, чиме се искључује окружење зграде.

Следећи опис представља кораке алгоритма:

Mask R-CNN сегментација позадине:

- Семантичка сегментација визуелне слике
- Проналажење маске према сегментованој слици која представља окружење
- Издвајање позадине применом пронађене маске у паралелним инфрацрвеним фрејмовима

## 2.3 RetinaNet

RetinaNet је детектор објеката који има хијерархијску структуру и настао је из инспирације визуелним кортексом. RetinaNet се заснива на ResNet мрежи која издваја карактеристике и на пирамидалној мрежи својстава FPN (Feature Pyramid Network), која обрађује мапе својстава из различитих нивоа. Пирамидални принцип у RetinaNet је сличан визуелном кортексу јер се у првој фази посматрања најпре региструју одређени облици, а уз повећану пажњу и околни објекти се препознају и коначно се достиже детаљна представа слике. RetinaNet је детектор објеката који


идентификује објекте и генерише оквири око њих. Објекти се локализују у току процеса вишеструког скалирања улазне слике и оквири за објекте се симултано прорачунавају.

За тренирање неуралне мреже искоришћен је сет слика „Window Detection in Street Scenes” који је јавно доступан, као и сет података који су добијени самим снимањем, при чему су на оптичким снимцима означене области прозора, врата, као и крова, како би се обезбедила класификација сегмената објеката. Током тренинга неурална мрежа учи да издвоји уопштене атрибуте са слике. У нижим слојевима то су линије, ивице, боје и једноставне форме, а на вишим нивоима текстуре, комбинације форми и делови објеката и други комплексни визуелни елементи.

RetinaNet се састоји од backbone мреже и од подмрежа за класификацију и регресију [29, 30]. RetinaNet backbone мрежа користи ResNet и FPN са две међусобно повезане путање, једном од дна ка врху и другом од врха ка дну, као што је представљено на слици 3. У путањи од дна ка врху је неколико конволуционих слојева. На излазима последњег резидуалног блока ResNet се добијају мапе својстава. На овај начин су повећане брзина и тачност детекције. На сваком нивоу пирамиде, на излазу се добијају мапе својстава истих размера. На различитим нивоима се користи stride 4, 8, 16 и 32. У путањи од врха ка дну се увећавају мапе својстава са виших нивоа пирамиде. Везом путања од дна ка врху и од врха ка дну побољшавају се својства тако што се мапе својстава исте резолуције уклапају.

У овој студији модел је трениран имплементацијом у Keras-у користећи Resnet50 неуралну мрежу. Дубока резидуална мрежа ResNet се састоји од више конволуционих слојева [31]. Помоћу skip веза се излази из претходних конволуционих слојева повезују са излазима наредног слоја. Resnet50 користи zero-padding. У првом конволуционом слоју се користи 64 филтера величине 7\*7 пиксела и stride 2\*2. Max pooling прозор је 3\*3 и користи се stride 2. Наредни блокови користе резидуалне везе. У другом блоку користе се 64, 64 и 256 филтера резолуције 1\*1, 3\*3, 1\*1 респективно. Наредни блок користи 128 филтера величине 1\*1, 128 филтера величине 3\*3 и 152 филтера димензије 1\*1. У блоку који следује користи се 256, 256 и 1024 филтера величине 1\*1, 3\*3 и 1\*1 респективно. У следећем блоку примењује се 512 филтера величине 1\*1, 512 филтера величине 3\*3 и 2048 филтера величине 1\*1. Pooling који узима средњу вредност има прозор 1\*1 пиксел. На крају мреже је FC слој који редукује улазе и омогућава класификацију користећи SoftMax активацију.

Користећи RetinaNet детектовани су прозори и врата на визуелним фрејмовима, чиме су генерисани оквири који истичу ове објекте. Поред тога су приликом детекције сачуване координате детектованих објеката. То је омогућило да се на паралелним термалним снимцима издвоје области које представљају прозоре и врата и да се на тај начин процене топлотни губици који се одвијају у овим областима.



Слика 3 FPN RetinaNet модела


## 2.4 CNN

Конволуциона неурална мрежа се уобичајено примењује у класификацији слика. CNN је развијена како би се препознали и детектовали објекти. Основни циљ је да се препознају поновљене регуларности, како се сви објекти могу представити једноставним формама. Процес конволуције подразумева увођење филтера у улазну слику или у мапе својстава које се добијају у процесу обраде слике. Конволуција подразумева операцију множења филтера и мапе својстава. Помоћу различитих типова филтера омогућено је издвајање одређених својстава на слици, као што су ивице, ивичне тачке, линије, контуре и групе тачака. Филтер клизи преко слике и тежишне вредности из филтера се мултиплицирају тренутним вредностима са рецептивног поља слике. Уколико је филтер представљен матрицом  $w$ , а улаз слике је представљен матрицом  $i$ , а  $b$  представља одступање, онда је излаз за појединачно рецептивно поље дат са:

$$o = w^T i + b \quad (7)$$

Овај процес се понавља преко читаве слике са димензијама  $x * y * 3$ , где су  $x$  и  $y$  дужина и ширина слике а  $3$  представља број канала. На излазу се добија онолико мапа својстава, колико је филтера примењено. Процес pooling-а се примењује на излазу за дате нове вредности на слици. У овом процесу смањује се резолуција издвојеног дела слике, често узимајући максималну вредност у оквиру посматраног региона или узимајући просечну вредност. На крају неуралне мреже је потпуно


повезани слој где на улаз долази вектор са издвојеним својствима и затим се обавља процес класификације и генерисања оквира око објеката.



Слика 4 CNN мрежа

Неурони у првом конволуционом слоју процесирају дефинисане мале сегменте улазне слике. Неурони у наредним слојевима су повезани са ограниченом групом неурона из претходних слојева. На конволуционом нивоу могу се применити различити филтери како би се издвојиле карактеристике. На излазу се добија мапа карактеристика, која означава области на слици које превасходно активирају филтар. Неурони из другог слоја су повезани са неуронима из првог слоја са ограниченим рецептивним пољем задатих димензија. Излазна функција неуралне мреже једнака је улазима из претходних слојева мреже помноженим одговарајућим тежинским фактором. На слици 5 представљен је процес конволуције.





Слика 5 Визуелни приказ принципа конволуционе мреже

У зависности од одабране скале боја инфрацрвеног инструмента, карактеристичне боје представљају хладна подручја, тј. подручја са интензивним губицима топлоте. Додатним алгоритмима детекције објеката могу се прецизно издвојити елементи зграда са критичним губицима топлоте. CNN је тренирана користећи прикупљени сет података сачињен од сегмената са карактеристичним тамним и светлим бојама који је добијен од направљених термалних снимака. Током тренинга мапе својстава садрже библиотеку визуелних елемената које могу препознати ове различите боје. Сачињена је конволуциона неурална мрежа CNN од конволуционих и pooling слојева.

Први конволуциони слој учи да прикаже једноставна својства као што су равне линије у одређеном правцу. Други слој може да представи ова једноставна својства на апстрактнији начин. Трећи конволуциони слој је dense слој тј. скривени слој који омогућава да се слике могу одговарајуће класификовати. У потпуно повезани слој долазе издвојени атрибути на улазу уместо пиксела. Мрежа је затворена једним SoftMax излазним слојем.

CNN мрежа је примењена за детекцију термалних мостова по површини фасаде. Помоћу sliding window приступа, на слици су анализирани прозори мале резолуције за које је испитано да ли представљају топлије зоне. Тиме су лоцирани мањи сегменти на самој фасади са повишеним температурама који указују на позицију области на фасади за које је, са великом вероватноћом потребно побољшати изолацију.

## 2.5 GAN

Generative Adversarial Network (GAN) је мрежа састављена од две дубоке неуралне мреже. Једна мрежа је означена као генератор у којој се генеришу слике засноване на предикцији. Друга мрежа је означена као дискриминатор и настоји да препозна стварне слике. Дискриминатор издваја својства да би се подудариле карактеристике у репрезентацијама оригиналне и генерисане слике. Генератор GAN мреже уобичајено ствара слику из случајног шума и у току тренинга почиње да генерише слике које су сличне оригиналној слици. Процес обучавања за генерисање нових слика одвија се без надгледања, тј. из неозначених података. Генератор и дискриминатор се симултано тренирају. Функција GAN представља min-max оптимизацију преко бинарног класификационог губитка и може се представити на следећи начин:

$$\min_{\alpha} \max_{\beta} E_{x \sim \mu} [\log f_{\beta}(x)] + E_{y \sim \nu} [\log (1 - f_{\beta}(g_{\alpha}(y)))] \quad (8)$$

Функција дискриминатора  $f: \chi \rightarrow [0,1]$  се тренира да на излазу даје високе вредности уколико је улаз реалан, а ниске вредности у супротном. У генератор и дискриминатор уведени су параметри  $\alpha$  и  $\beta$ , означени као  $g_{\alpha}$  и  $f_{\beta}$  респективно. Објективна функција је максимизована преко параметра дискриминатора  $\beta$  да би се дискриминатор боље обучио за класификацију и минимизована преко параметра генератора  $\alpha$ . GAN се користи за генерисање слике, видеа, у динамичкој 3D реконструкцији, као и за генерисање и превод текста.

GAN мрежа је примењена за поређење снимака истог објекта под различитим спољним условима, због осетљивости инфрацрвених мерења на промењене спољне услове. Тиме је испитана вероватноћа да су термалне слике дале исте резултате.

## 2.6 K-Means

KMeans алгоритам се користи као техника кластеризације којом се слика рашчлањује на сегменте. Најпре се лоцирају такозвани центроиди слике, који представљају карактеристичне вредности пиксела у смислу тробојне скале RGB, а затим се сваки пиксел асоцира са најближим центроидом. Пиксели на тај начин раздвајају регионе слике, што је важно у утврђивању већих топлотних губитака. Области захваћене топлотним губицима уочљиве су као светлије боје. Кластеризација путем KMeans алгоритма, омогућава да се јасније издвоје ове области. KMeans дозвољава да се дефинише број кластера.

KMeans принцип се може представити следећом формулом:

$$y = \sum_{j=1}^k \sum_{i=1}^n |x_i^{(j)} - c_j|^2 \quad (9)$$

где  $y$  представља функцију циља,  $k$  представља број кластера,  $n$  је број параметара и  $c_j$  је центроид кластера. Разматрајући дистанце између тачака, алгоритамски се прорачунавају вредности које су најближе претходно дефинисаним класама.

Применом KMeans алгоритма истиче се контраст између различитих области на инфрацрвеној слици, груписањем пиксела према репрезентативној боји центра кластера. Алгоритам је брз и даје визуелну дескрипцију анализираних објекта, при чему се број различитих кластера може унапред дефинисати.

KMeans је у овој студији употребљен за кластеризацију инфрацрвених слика, како би се ефикасно пронашле топле и хладне регије. Поређењем центара кластера са скалом боја, утврђене су области са вишим и нижим температурама. То је омогућило и локализацију ових региона на инфрацрвеним сликама, што је употребљено као улаз у GAN мрежу за поређење снимака направљених у различито доба.

## ПОГЛАВЉЕ 3

### 3.1 Дизајн система за класификацију енергетске ефикасности зграда

За систематску анализу топлотних губитака дизајниран је нови метод за евалуацију енергетске ефикасности грађевинског објекта. Овај метод обухвата испитивања перформанси објеката без обзира на типове топлотних губитака. Дијагностиком се могу утврдити недостаци функционалности изолације објеката и запазити ефекти термалних процеса на структури зграде. Термална радијација је преведена у температуру и регистрована варијанса температура на површини указује на присуство губитака за издвојене површи зграде. Од прикупљених снимака грађевинских објеката најпре су на визуелне фрејмове примењене библиотеке компјутерске визије, којима се може утврдити да ли су на секвенцијалним фрејмовима приказани исти објекти. Затим су утврђени њихови позициони параметри у односу на угао снимања, што је омогућило аутоматско издвајање оних секвенци које су сачињене директно ка грађевинском објекту. У наредној фази су визуелни снимци скалирани да би се омогућило њихово уклапање када је у питању резолуција. Након тога је спроведена сегментација визуелних фрејмова, што је обезбедило издвајање позадине са термалних снимака. Помоћу детектора објеката детектовани су прозори и врата који су на паралелним термалним снимцима издвојени. Издвојен је и кров. Преко скале боја и температура која се може прилагодити задатим спољним условима, процењене су температуре појединих сегмената зграде и одређено је колико процентуално зграду захватају топлотни губици. Упоредне су температуре и утврђено је на којим конкретним елементима долази до губитака топлоте и процењена је изолациона моћ.

### 3.2 Сет података и тренирање модела

Како би се испитало присуство губитака топлоте искоришћена је недеструктивна анализа помоћу инфрацрвене радијације. Користећи беспилотну летелицу добијени су подаци за различите зграде чије су фасаде снимљене са дистанце. Беспилотне летелице са малим теретом су економичне и омогућавају брзо и ефикасно прикупљање података и обраду. Њиховом применом могу се за најкраће време прикупити велике количине слика високе резолуције. То омогућава чешћу визуелну инспекцију фасада зграда из непосредне близине. Инфрацрвене камере високе резолуције дају детаљне информације о расподели температура, којима се могу уочити термалне аномалије, проузроковане недостацима или оштећењима на фасади.

Употреба беспилотних летелица у области науке и технологије је последњих година значајно порасла и примењује се у трагању за спасавањем, даљинском детектовању и праћењу саобраћаја на путевима у реалном времену. У [117] представљен је критички преглед литературе о употреби беспилотних летелица како би се указало на најшире коришћене технике и поља примене. Посебно у изградњи и у испитивању стања зграда постоје широке могућности за употребу беспилотних летелица. За разлику од устаљених метода за прикупљање података, ова метода омогућава сигурни и једноставни приступ свим деловима зграде.

Термографско испитивање је спроведено користећи беспилотну летелицу DJI Mavic Enterprise dual, опремљену оптичком и инфрацрвеном камером које истовремено снимају окружење. Тиме је спроведено ефектно инфрацрвено испитивање за велики број објеката, како зграде могу бити снимљене са свих позиција. На овај начин су снимљене зграде једне области које су сачињене од различитих материјала. Омогућено је испитивање термалних својстава зграда различитих изолационих материјала и обезбеђен је вредан сет података, који је био база за креирање модела вештачке интелигенције за класификацију стања изолације за зграде. Чак и високе зграде могу бити снимљене на овај начин укључујући и кровове које је тешко достићи. Карактеристике беспилотне летелице су представљене у табели 1.

Табела 1 Техничке карактеристике камера беспилотне летелице

<b>Опсег температура</b>	-10 °C до 40 °C
Резолуција визуелног сигнала	1920 x 1080
Резолуција термалног сигнала	640 x 360
Спектрални опсег	8 $\mu\text{m}$ до 14 $\mu\text{m}$
Осетљивост мерења	<50 mK

Уређај омогућује тачна, бесконтактна температурна мерења дајући податке који су уграђени у фрејм слике. Бесконтактна мерења помоћу беспилотне летелице омогућују термалну видљивост површине фасаде и прикупљање података са спољних позиција зграде са произвољне висине. У студији [74] описали су протокол инспекције индустријске зграде беспилотном летелицом, показујући могућности ове технологије да скупни корисне информације у комбинацији са потенцијалним откривањем термалних аномалија путем термографије.

Постоје бројни фактори који утичу на тачност мерења приликом инфрацрвеног испитивања. Један од важних предуслова успешног испитивања је температурна разлика између унутрашњости и спољашњости објекта од најмање 10 °C што је било испуњено у току испитивања.

Пошто су при испитивању истовремено снимљени различити објекти, подразумева се заједничка вредност за емисивност која одговара процењеној вредности за објекте од цигле и бетона. Међутим за појединачне објекте, који су конструисани од специфичних материјала, као што је метал, може бити потребно


посебно подешавање емисивности у складу са карактеристикама материјала. За материјале са малом емисивношћу веома мале варијације у емисивности утичу на веома велике варијације температуре. Овакви материјали се карактеришу великом рефлексивношћу.

Приликом мерења, потребно је узети у обзир утицај спољашњих температурних извора. Да би се смањило утицај сметњи околине на прикупљање података о температури, инфрацрвена мерења су спроведена при облачном времену, са малим снагама ветра, како би се избегли конвективни губици топлоте. Временски услови и доба дана су одабрани тако да омогућују успешно инфрацрвено испитивање. Термалне карактеристике зграде зависе од инсталиране изолације и постоји већа термална отпорност уколико постоје заштитни слојеви на фасади. Топлота протиче спорије кроз изоловане зграде. Колико се топлотне енергије преноси кроз зидове зависи од материјала зграде. Испитиване зграде направљене су од цигле и бетона који су карактерисани већом емисивношћу, због чега се фактори рефлексije и трансмисије могу занемарити.


У овој студији је искоришћен удаљено управљан дрон да би се обезбедило ефективно и брзо прикупљање података које покрива ширу површину зграда користећи термалну камеру. Настојало се да се развије ново систематско прикупљање података, које омогућује да се инфрацрвена инспекција једноставно спроведе на високим зградама. Анализирани су губици топлоте, одсуство термалне изолације, као и продирање ваздуха на спољашњости зграде.

Снимањем зграда дроном добијени су упарени визуелни и термални видео записи. Прва обрада добијених података подразумевала је синхронно издвајање слика из снимака које су објављене [119], чиме је омогућена детаљнија обрада и анализа термалних слика објеката. Приликом тренирања неуралне мреже искоришћени су подаци добијени снимањем дроном и сет података прозора “Window Detection in Street Scenes” који је доступан [73], чији су модели међутим приликом тестирања показали слабију тачност од модела добијеног тренирањем користећи генерисани сет података. Креирани сет података је пре тренинга модела било неопходно програмски припремити мануелним означавањем врата и прозора, тако да су утврђене координате оквира око објеката на свакој слици, што је потребно да би мрежа након надгледаног учења могла да предвиди позиције објеката тј. да их детектује.

У току тренирања модела добијени су графици у TensorFlow на којима се уочава прогрес учења својстава на сликама, која одликују дефинисане објекте. Уочљиво је да просечна прецизност модела расте са бројем поновљених операција тренинга. Наредне слике приказују параметре који означавају процес тренирања мреже [145].



(a)



(b)

Слика 6 Средња просечна прецизност при тренирању модела (a) сетом података Window Detection in Street Scenes, (b) генерисаним сетом података [145]

RetinaNet модел заснива се на ResNet50 Backbone мрежи и претходно је био трениран помоћу Coco сета података. Модел је трениран у Keras-у са задатим

тежинама imagenet у 50 епоха за “Window Detection in Street Scenes” сетом података. Сlike из овог сета података су селектоване из сета података “Paris Street View” и он се састоји од три типа података. У првом директоријуму је 1300 слика са просечно 7 прозора на свакој слици. Други директоријум садржи фајлове са означеним координатама прозора. У трећем директоријуму су три фајла у којима је листа слика које се користе за тренирање, валидацију и тестирање детектора. Прецизност овог модела није дала одговарајуће резултате, јер прозори нису били у целости детектовани, што отежава коректно испитивање елемената зграде. На многим визуелним сликама резултати детекције су показали да велики број прозора није био детектован. Због тога се приступило тренирању модела помоћу прикупљених података, при чему су креирани фајлови исте структуре као и у претходном сету података.

Да би се термални снимци зграда могли анализирати, захтевало се да је детекција елемената зграде прецизна. Добијени модели детектора објеката засновани на RetinaNet алгоритму су примењени на сету слика и њихова тачност је утврђена употребом параметара за одређивање прецизности модела. Precision се дефинише као однос позитивно детектованих објеката и збира позитивних и погрешно позитивних детекција. Параметар recall дефинисан је као однос позитивних детекција и збира позитивних и погрешно недетектованих објеката. На основу ових параметара добија се параметар F1, који се израчунава као однос двоструког производа прецизности и recall параметра и њиховог збира. Валидност детекција на свим сликама је била испитана и утврђено је да је модел заснован на креираном сету података био знатно прецизнији. F1 параметар представља посебан случај параметра F, када је  $\beta=1$  која представља тежински фактор релативног односа истински позитивних и погрешно негативних детекција и погрешно позитивних детекција [72].

$$F_{\beta} = (1+\beta^2) \frac{Precision \times Recall}{\beta^2 \times Precision + Recall} \quad (10)$$

### 3.3 Алгоритми за иницијалну обраду снимака

Из оптичких и термалних видео записа су најпре одабрани фрејмови што је био први корак у припреми података. Најзначајнији циљ био је да се издвоје интересантни подаци који би указали на слабу изолацију на грађевинским конструкцијама.



### 3.3.1 Груписање фрејмова са истим објектом

Приликом инфрацрвеног снимања беспилотном летелицом могу се појавити поновљене структуре које приказују слична својства на сликама. Мале варијације у мерењима се могу догодити услед угла инциденције или мале промене угла снимања због лета дрона. Један од изазова анализе и класификације енергетске ефикасности зграда је издвајање снимака који у целости приказују објекат. Након прикупљених података направљених дроном потребно је извршити њихову обраду како би се издвојили они инфрацрвени снимци који на најповољнији начин приказују термичке карактеристике одређеног објекта. Како би се постигла тачнија анализа зграде, неопходно је фокусирати се на фрејмове који на оптималан начин представљају сваку зграду. То подразумева директан поглед ка згради, како угао снимања приликом испитивања може утицати на мерења површине температуре. Очекује се да инфрацрвене слике које су добијене под правим углом представљају најпоузданија температурна мерења за зграде.

Добијени секвенцијални снимци су посебним алгоритмом који укључује подударане темплејта груписани тако да алгоритам препознаје да ли се одређена група фрејмова односи на исти објекат. Како би се упоредили узастопни снимци потребно је дефинисати метрику која одсликава њихову сличност. Помоћу функције `matchTemplate()` библиотеке `OpenCV` проналазе се подударанја између референтне слике и тренутног фрејма. Овај алгоритам прорачунава нормализовани коефицијент корелације подударанја између две слике [146]:

$$E_{CON} = \frac{\sum_{k,m}(I_{REF}(x_k,y_m)-I_{REFM})(I_1(x_k+u,y_m+v)-I_{1M})}{\sqrt{\sum_{k,m}(I_{REF}(x_k,y_m)-I_{REFM})^2}\sqrt{\sum_{k,m}(I_1(x_k+u,y_m+v)-I_{1M})^2}} \quad (11)$$

$$I_{REFM} = \frac{1}{N} \sum_{k,m} I_{REF}(x_k, y_m) \quad (12)$$

$$I_{1M} = \frac{1}{N} \sum_{k,m} I_1(x_k + u, y_m + v) \quad (13)$$

где су  $u$  и  $v$  промене позиција по  $x$  и  $y$  координатама слике ради упоређивања пиксела који се поклапају,  $I_{REF}$  је референтна слика а  $I_1$  је слика са којом се врши упоређивање,  $N$  је укупан број пиксела слике. Нормализовани коефицијент корелације се креће у опсегу од  $-1$  до  $1$ , што олакшава упоређивање слика.

На овај начин извршено је груписање фрејмова који се односе на исти објекат. Тиме је омогућено издвајање секвенци са оптималном перспективом. Важан аспект приликом обраде података је коректна представа структуре зграде у погледу њене

геометрије као и узимање у обзир параметара материјала зграде. То захтева тачно и потпуно разматрање стања зграде, иако је за старије грађевине документација често недоступна. Визуелни снимци обезбеђују преглед грађевинског објекта у погледу материјала и генералног стања грађевине. Због тога су груписани фрејмови за појединачне грађевинске објекте вредан скуп информација о типу материјала и остању фасаде, чиме се додатно поткрепљују налази добијени аутоматском обрадом.

### 3.3.2 Селекција перспективе користећи Canny метод и HoughLines детектор

Од слика истог објекта потребно је издвојити оне које су практично нормалне на посматрану зграду, како би инфрацрвена слика што квалитетније показала енергетске карактеристике. Како су зграде снимљене из различитих углова у току лета беспилотне летелице, примењен је механизам којим се локализују линије на слици као и њихов угао и проналази минимални угао и издвајају се фрејмови са одговарајућим објектом који су снимљени практично директно ка згради. Метод који је у широкој употреби за издвајање ивица објеката је Canny алгоритам који користи Gaussian filter за уклањање шума. Hough transform је детектор који је базиран на Canny edge детекцији и може издвојити линије са слике. Canny механизам укључује алтернативне филтере за детекцију контура на слици, који се може применити када је потребно одредити оштре ивице. То омогућава издвајање линија које прате спољашњост зграде као и одговарајућих углова помоћу Hough трансформације. Према овом принципу свака ивична линија може бити тачка пресека свих линија које кроз њу пролазе. Помоћу ове методе могу се идентификовати дужи које су добијене помоћу Canny edge детектора, које се налазе на истој линији. Како се слика посматра у  $(x, y)$  координатном систему, где је линија дата једначином:

$$x = a \cdot y + b \quad (14)$$

где  $a$  представља коефицијент смера,  $b$  представља одсечак линије. Ова једнакост се трансформише у  $(a, b)$  раван и постаје:


$$b = -y \cdot a + x \quad (15)$$

Користећи ово мапирање може се закључити да уколико једна линија пролази кроз две тачке  $(x_1, y_1)$  и  $(x_2, y_2)$ , онда ће у  $(a, b)$  равни то представљати пресек две линије.



Слика 7 Принцип Hough трансформације: (а) представа слике у  $(x,y)$  равни, (б) трансформација линија у  $(a, b)$  равни

На излазу овог алгоритма се добија вредност пиксела одсечка линије и одговарајућег угла пресека  $\theta$ . Циљ је да се међу сукцесивним сликама за исту зграду, селекују оне које имају минимални угао  $\theta$  за доњу детектовану линију, што даје оптималну перспективу за грађевину.



Слика 8 Детектоване линије објекта




Слика 9 Издвојени снимак који је направљен директно ка објекту

Овај алгоритам је омогућио да се упореде различите перспективе за исти објекат и да се селекују фрејмови направљени из оптималног угла. Тиме су избегнуте варијације у термалним мерењима за исти објекат услед промењеног угла снимања, јер се из различитих перспектива добијају другачији прикази истог грађевинског објекта због различито измереног сигнала.

### **3.3.3 Алгоритам за подударање визуелних и инфрацрвених снимака**

Важна припрема пре ефективне термалне анализе је и уједначавање одабраних визуелних секвенци снимака и одговарајућих термалних слика. Примећено је да су на термалним снимцима објекти сужено представљени, за разлику од оптичких снимака који са знатно већом резолуцијом приказују објекте у целости. Због различитих резолуција оптичке и термалне камере, поравнање паралелних секвенци постигнуто је постепеним смањењем визуелне слике ради подударања са термалном сликом.

Алгоритамским скалирањем инфрацрвеног и оптичког фрејма, омогућује се аутоматска обрада ових слика и паралелна локализација области и објеката са интензивним губицима топлоте. На овај начин се приликом симултане детекције и издвајања прозора и врата смањује грешка до које долази уколико су слике несразмерних димензија и уколико је већи угао под којим је зграда снимљена, јер се омогућује да се искључиво издвоје они делови зграде који се подударају са оптичким снимком.



Слика 10 Адаптирање резолуције визуелних и термалних фрејмова

У овом истраживању алгоритми вештачке интелигенције су примењени како би се класификовали објекти према њиховој изолацији. Овом методом су издвојене компоненте зграде које представљају ограничене области фасаде које су анализиране. Затим су издвојени сегменти испитани како би се дала целовита слика о функционалности фасаде и покрила широка област термалне анализе.

Представљен је метод којим се визуелно разликују региони који припадају прозорима или вратима и регионима фасаде како би се прорачунао њихов удео при одређивању топлотних губитака зграде и одредили могући енергетски губици за испитиване конструкције.

### 3.3.4 Сегментација слике за испитивање зграде


Уједначене паралелне инфрацрвене и визуелне слике се могу симултано обрадити користећи дубоку неуралну мрежу. Употребљен је модел који се заснива на Mask R-CNN-у за сегментацију слике са циљем да се филтрирају зграде на сликама и уклоне околни објекти који могу утицати на тачност у алгоритамској анализи зграда. Сегментација инстанци је спроведена користећи претходно тренирану дубоку неуралну мрежу која класификује различите објекте на сценама у граду помоћу боја карактеристичних за дату класу групишући пикселе који припадају истој класи.

Визуелни и инфрацрвени снимци су обрађени помоћу семантичке сегментације употребом deeplabv3 модела, који је трениран сетом података Ade2K. Deeplabv3 модел је заснован на Atrous конволуцији која омогућава да се добију различите резолуције издвојених својстава и даје мапе својстава које се заснивају на уношењу прекида између тежина филтера. Издвојене карактеристике се обрађују за различите скалиране сегменте. Додатни модул обезбеђује препознавање сличности вредности пиксела. Atrous Spatial Pyramid Pooling уводи класификацију сваког пиксела и на излазу се добија сегментована слика у оригиналној величини. Ade20k сет података садржи сцене са означеним сегментима на сликама за 150 различитих категорија.



Слика 11 Сегментација визуелног фрејма

На слици 11 приказан је пример једног визуелног снимка на који је примењена сегментација слике помоћу Mask R-CNN мреже. Може се уочити да су различити објекти раздвојени према пикселима и означени другачијим бојама: кола су означена плавом бојом, дрво је представљено зеленом бојом а зграда је издвојена браон нијансом. Паралелни визуелни и инфрацрвени фрејмови који су претходно скалирани тако да се подударају, обрађени су коришћењем библиотека компјутерске визије у Python-у. Пошто сегментација визуелне слике омогућава класификацију различитих објеката према боји, тиме су добијене маске за објекте из околине које су примењене на одговарајуће инфрацрвене снимке и то је омогућило издвајање позадине и објеката у околини.



Слика 12 Издвојена позадина

### 3.3.5 Детекција објеката за издвајање индивидуалних делова

Следећи снимци представљају резултате који су добијени обрадом визуелних фрејмова користећи тренирани детектор објеката помоћу RetinaNet за детекцију објеката. Детекција објеката представља класификацију и локализацију вишеструких објеката на сликама. Локализовање објеката је процес којим се предвиђају оквири око објеката, што су уобичајено хоризонталне и вертикалне координате око објекта. Прорачунава се вероватноћа да је објекат присутан на слици и проналазе се највише вредности.

Модел за детекцију објеката је креиран на основу претходно трениране мреже имплементацијом у Keras-у. Сет података садржи слике и податке са означеним координатама објеката одређених класа на сликама, који су употребљени за тренирање мреже. ResNet користи повратне везе и блокове. У оквиру ових веза, обављају се batch нормализација и ReLu активација и излаз ових блокова и улаз се додају у вези. Употребом овог алгоритма добијају се оквири око објеката и њихове одговарајуће координате и помоћу новог алгоритма су ове координате пресликане на паралелне термалне слике, ради издвајања елемената.

Примењујући добијене координате прозора и врата на инфрацрвеним снимцима, однос између расподеле боја прозора и фасаде је анализиран да би се одредили топлотни губици.

Наредне слике приказују резултате детекције прозора помоћу два различита модела где се може приметити да је први модел прецизно детектовао прозоре. Насупрот томе, други модел је на једном фрејму детектовао само пола прозора, а на другом фрејму је неколико прозора и врата остало недетектовано. Поред тога се може уочити да су код другог модела оквири око прозора знатно шири од димензија прозора. Издвајање прозора би стога довело до значајнијих грешака у прорачунима.



Слика 13 Детектовани прозори моделом тренираним помоћу генерисаног сета података





Слика 14 Детектовани прозори моделом тренираним помоћу Window Detection in Street Scenes сета података

#### Детекција прозора и врата:

- Применом тренираног детектора објекта детектују се прозори, врата и кров на издвојеним снимцима
- Издвајају се координате ових елемената који су локализовани на визуелном фрејму
- Коришћењем добијених координата издвајају се компоненте са инфрацрвених фрејмова

Овим путем је омогућена посебна анализа прозора и фасаде у којој се проналази термална дистрибуција, што представља основу за компарацију снимљених температура и омогућује анализу преношења топлоте кроз материјале на објекту.

### 3.3.6 Детекција термалних мостова на фасади зграде

Помоћу креираног супервизованог модела заснованог на CNN структури, примењује се и алгоритам који са коначног облика фасаде грађевине, добијеног претходним обрадама селектованих снимака, издваја светлије делиће који указују на топлотне губитке. Ток овог алгоритма је имплементиран поделом читавог фрејма на мале сегменте помоћу тзв. клизног прозора (sliding window), који издваја сваки сегмент слике и врши класификацију на позитивне и негативне детекције термалних губитака.

CNN је била тренирана користећи TensorFlow и обухватала је 2D конволуциони слој са 32 филтера на улазној слици са 3\*3 рецептивна поља и са улазном величином од 28\*28 пиксела и 1 црно-белим каналом. Сваки филтер садржи сет тежина којима се издвајају карактеристике. У наредном 2D MaxPooling слоју се 2\*2 региона учитавају у слику, у којем се слика ограничава, да би се смањило оптерећење при процесирању као и коришћење меморије. У овој фази редукују се димензије слике тако што се прорачунава максимална вредност из дефинисаних региона, што омогућује добијање мањих репрезентација слике. Као и код конволуционог слоја, сваки неурон овог слоја је повезан са излазима ограниченог броја неурона претходног слоја, локализованог у оквиру малог правоугаоног поља. Међутим, у овом слоју нема тежина, већ се сакупљају улази користећи агрегациону функцију максимума. То значи да искључиво максимална вредност сваког рецептивног поља доводи до следећег слоја, док се други улази испуштају. Наредни слој све јединице укључује у један заједнички слој јер се очекује једнодимензионални улаз карактеристика сваке инстанце, следећи dense слој обухвата 128 јединица у оквиру скривеног слоја, слој са 50% фреквенцијом испуштања како би се смањила претренираност и потом dense излазни слој са SoftMax активацијом са 10 јединица које се преносе ка излазу ради дистрибуције вероватноћа.

Улазна слика која представља низ пиксела подељена је на сегменте тј. прозоре резолуције 28x28 пиксела. Претходно примењеном сегментацијом слике је околина анализиране зграде означена црном бојом, да се ови региони не би разматрали. Алгоритам за сваки прозор на слици најпре проверава да ли је означен црном бојом прорачунавајући хистограм за мали сегмент и поредећи га са хистограмом црног узорка истих димензија. Тиме је омогућено, да се предикција зона са већим температурама путем CNN обавља само за оне сегменте слике који нису део позадине. Алгоритам се заснива на надгледаном учењу, у којем су улазни подаци делови слике, а на излазу се добијају уоквирени прозори за суседне сегменте са детектованим губицима топлоте.

Следећи опис се односи на поступке овог програма.

Детекција термалних мостова:

- Користећи клизни прозор на слици, испитује се за сваки да ли се може окарактерисати као топлотни губици
- Уколико се применом CNN низ прозора улазне слике детектује као топлотни губици, генеришу се оквири који указују на термалне мостове

Овим је омогућено да се детектују термални мостови по површини фасаде, како би се локализовале регије са спољашњим зидовима са топлотним губицима за које би било потребно утврдити узрок и омогућити унапређење изолације.

### 3.3.7 Процена температуре за индивидуалне сегменте

Температуре су процењене помоћу учитане скале боја која је добијена користећи Flig програм за обраду инфрацрвених снимака. Како би се утврдиле и упоредиле температуре појединих сегмената зграде, потребно је утврдити референтне вредности које омогућавају поређење. Температуре се процењују на основу палете, за коју се температурни опсег може дефинисати најнижом и највишом температуром. Поредиши издвојене RGB боје са тоновима са скале користећи минималну еуклидијску дистанцу, процењене су спољне температуре различитих компонената:

$$E_{xyk} = \sqrt{((R_{xy} - R_k)^2 + (G_{xy} - G_k)^2 + (B_{xy} - B_k)^2)} \quad (16)$$

где су  $(R_{xy}, G_{xy}, B_{xy})$  боје датог пиксела са координатама  $x$  и  $y$  и  $(R_k, G_k, B_k)$  представља тон палете који одговара температури  $T_k$ .

За нижу температуру скале ради прорачуна, узета је спољна температура, а за вишу температуру скале одређена је просечна унутрашња температура од  $20\text{ }^\circ\text{C}$ . Инфрацрвена мерења показују да ова претпоставка одговара реалним ситуацијама. Како је скала подељена у различите опсеге боја, претпоставка је да су ови опсези униформно подељени и у складу са тим је претпостављена униформна расподела температура, јер се за мале разлике нијанси у палети боја могу претпоставити мали кораци температурних разлика. На овај начин је остварена процена температура и анализа температурних разлика.

Прилагођавање температурне скале:

- Може се дефинисати минимална и максимална мерена температура
- Опсег температура се мапира према учитаној палети под претпоставком линеарних губитака топлоте

Издвајање температура фасаде:

- За обрађену слику прорачунава се укупан број пиксела, при чему се не разматрају области са издвојеним сегментима са снимка
- Прорачунава се проценат пиксела
- За најзаступљеније нијансе проналазе се путем мапе палете и температура процењене температуре користећи еуклидијско растојање са RGB представом боја на скали
- Одређује се средња вредност температура

Издвајање температура прозора, врата и крова:

- За сваки пиксел прозора проналази се представљена боја и прорачунава се број пиксела
- Прорачунава се проценат пиксела
- За тонове са највећим процентом прорачунавају се путем мапе палете и температура, процењене температуре одређивањем њиховог еуклидијског растојања у односу на RGB представу палете и одређује се средња вредност температура прозора

### **3.3.8 Поређење термалних губитака између елемената зграде**

Прорачунавање варијације температура:

- Одређују се температурна одступања између појединачних сегмената
- Укључена је варијација температуре 2.55 °C која је добијена теренским квантитативним мерењима
- Укључена је кластеризација елемената методом KMeans којом се категорише издвојена компонента зграде према скали боја као топла област или као хладна област, што је укључено у упоређивање компоненти

### **3.4 Локализација незадовољавајуће изолације на зградама**

#### **3.4.1 Девиијација губитака топлоте између прозора и фасаде**

Прозори су најчешће елементи на којима су најинтензивнији топлотни губици. Већа количина топлоте која пролази кроз прозоре је најчешће видљива као светла боја на инфрацрвеним сликама. Често старије зграде имају старије уграђене прозоре, који могу бити са једнослојним стаклом и стога слабије изоловани. Честа појава код старијих прозора је и кондензација, јер топли ваздух изнутра долази у додир са хладним површинама прозора због слабе изолације и продора хладног спољњег ваздуха. Модернији прозори могу имати и до три слоја стакала, што обезбеђује знатно бољу изолацију. Заменом прозора бољег квалитета значајно се може уштедети енергија. Са термографских снимака са великом поузданошћу се брзо може утврдити да ли постоје значајни губици топлоте кроз прозоре, што је уочљиво као више температуре прозора у односу на фасаду. Термалне слике могу препознати различите аномалије на прозорима, као што су струјање ваздуха кроз оквири и влага. Међутим предуслов је да прозори у тренутку испитивања нису отворени.

Добијене су различите вредности температурних промена између прозора и фасаде. У појединим случајевима та разлика је око 3 °C. Приликом класификације потребно је дефинисати праг који указује на граничне вредности односа топлотних губитака. Теренским мерењима је прорачуната средња вредност грешке 2.55 °C за измерене температуре, па је за значајнија температурна одступања дефинисан праг од 5 °C.


#### **3.4.2 Девиијација губитака топлоте између врата и фасаде**

Код врата такође може бити уочљив проток ваздуха, када су присутни мали прорези око оквира врата, што се превасходно може догодити у хладним периодима и при јаком ветру. Тада се слично као на прозорима могу детектовати високе температуре око оквира и на површини врата.

За издвојена и детектована врата прорачунавају се варијације температуре у односу на фасаду. Врата међутим обухватају најчешће мању површину у склопу испитиваног објекта и у поређење се стога укључује у процентуални удео површине зграде заједно са прозорима.

### 3.4.3 Испитивање изолације већих елемената

За испитивање кровне конструкције примењен је Sunny детектор за проналажење контура на оптичком фрејму, који је помоћу добијене маске пресликан на одговарајућој инфрацрвеној слици. Кров је био локализован примењујући подударале темплејта помоћу нормираног корелационог стандарда на сегменте слике користећи сет слика крова. Помоћу истог програма који је примењен и за процене температуре фасаде, и за ову област се може проценити средња температура. То могу бити у посебним случајевима и други сегменти зграде.



Слика 15 Издвојени кров

### 3.5 Значај детектованих губитака за индивидуалне сегменте

Поред тога што се овим путем могу проценити температурна одступања између појединачних елемената и фасаде, како би се извршила класификација изолације, уведено је поређење захваћених површина које се односе на прорачуната температурна одступања. Тако се прорачунава и однос површине прозора према површини фасаде, да би се уочио процентуални део захваћеног подручја губицима.

Такође се може дефинисати праг за губитке топлоте на фасади или на прозорима. У једном од наведених примера су процењене температуре површине прозора преко 17 °C, што указује на значајне топлотне губитке и може ефективно утицати на класификацију изолације објекта.

### 3.6 Укупна анализа зграде

Коначна анализа једног објекта обухвата следећа питања:

- Да ли је значајна варијација у разлици температура између појединачних елемената и фасаде? Уколико су ове вредности значајно различите, више температуре указују на области са већим топлотним губицима и то су најчешће прозори. То може указати на потребу да се ове компоненте додатно изолују. На зградама прозори уобичајено заузимају велику површину и стога имају значајан утицај на енергетску ефикасност. Алгоритам прорачунава и степен захваћености топлотним губицима. Уколико су примећени већи топлотни губици на фасади, они указују на њену слабу изолацију и на потребе мера њеног побољшања
- Пошто је природа оваквог прикупљања података таква да се могу догодити непланирани догађаји, као што су отворени прозори који би приказивали већи проток топлотне енергије, потребно је и испитати оптичке снимке зграда, који могу указати на овакве појаве. Оптички снимци могу указати и на оштећења фасаде
- Уколико није значајна разлика у температури појединачних елемената и саме фасаде, под претпоставком да се објекат у зимском периоду загрева, уколико процењене температуре на спољашњости зграде имају ниже вредности, може се закључити да је објекат добро изолован. Уколико су међутим процењене високе температуре на спољашњости зграде, то указује на значајне топлотне губитке и на недовољну изолацију

Алгоритам на излазу даје резултате обраде инфрацрвених снимака грађевинског објекта и указује на елементе зграде на којима се губи топлота. Методологија у овој студији односи се пре свега на анализу термографских слика и на тој основи се врши класификација објеката. Прикупљени оптички записи дају додатне информације о стању грађевинског објекта, а на њих би се могли применити и различити алгоритми за детекцију пукотина и аномалија који су испитани у досадашњим истраживањима. Увођењем односа захваћених површина зграде, омогућена је процена значаја области које су захваћене топлотним губицима за читаву зграду.

### 3.7 Класификација објекта

Класификацијом је потребно утврдити да ли је стање зграде прихватљиво или не. Уколико су детектоване више температуре, то може указати на потребу за побољшањем изолације. У овом одељку описано је формирано разумевање свеукупних термалних перформанси зграда, на основу процењених температурних података.

Како би се добила представа о губицима топлоте, алгоритамски се издвајају карактеристичне боје са слика. За издвојене прозоре и врата проналазе се најзаступљеније нијансе на термалној слици које се затим мапирају у температуре према температурној скали. На тај начин се могу уочити одступања за појединачне елементе.

Алгоритам који приказује специфичне елементе на инфрацрвеној слици специфично истиче најзаступљеније боје и њихов проценат на слици. Однос између добијених вредности за издвојене прозоре и врата је прорачунат да би се омогућило закључивање које се односи на стање изолације прозора и врата. Такође се уводи и стандардна девијација, како би се дошло до што тачније процене. Прорачунава се и површина региона, како би се у анализи узела у обзир и захваћеност грађевинског објекта топлотним губицима. Помоћу кластера инфрацрвених слика дефинисане су топле и хладне области. У табели су представљени фактори којима се спроводи поређење компонената зграде и класификација изолације.

Табела 2 Издвојени подаци за области грађевине

<i>Прозор 1</i>	<i>Прозор 2</i>	...	<i>Прозор n</i>	<i>Врата</i>	<i>Фасада</i>
T1	T2	...	Tn	Td	Tf
Tf-T1+σ	Tf – T2 + σ	...	Tf – Tn + σ	Tf – Td + σ	Tf+σ
Површина региона	Површина региона	...	Површина региона	Површина региона	Површина региона
светлост	светлост		светлост	светлост	светлост

Глобални метод за класификацију грађевина:

Израчунава се фактор захваћене површине  $S_o/S_f$

Ако је  $T_o$  и  $T_f > T_{high}$ : фасада и објекат имају топлотне губитке иначе:

ако је  $T_o > T_f$  тада:

ако је  $T_o - T_f + \sigma > T_r$ :

ако је  $S_o$  светла тада:

ако је  $S_f$  површине светла тада: фасада и објекат имају губитке топлоте

иначе: део има губитке топлоте у %

у супротном:

део има губитке у %

у супротном:

нема налаза о лошој изолацији

иначе ако је  $T_f > T_o$  онда:

ако је  $T_f - T_o + \sigma > T_r$ :

ако је  $S_f$  светла, онда фасада има губитке топлоте



ако је  $S_o$  светла, онда фасада и објекат имају губитке топлоте

иначе: фасада има губитке топлоте

у супротном: фасада има значајно веће губитке топлоте.

у супротном:

нема налаза о лошој изолацији

иначе ако је  $T_f = T_o$  тада:

нема налаза о лошој изолацији

при чему  $S_o$  представља површину објекта,  $S_f$  представља површину фасаде у пикселима,  $T_o$  представља процењену средњу температуру објекта,  $T_f$  представља процењену средњу температуру фасаде,  $T_{high}$  је праг високих температура, а  $T_p$  је температура прага,  $\sigma$  је варијанса.

### 3.8 Грешка

У представљеним прорачунима полази се од претпоставке да је унутрашња температура просечно  $20\text{ }^\circ\text{C}$ . Међутим унутрашња температура објекта утиче на прорачуне и због тога је, ради прецизнијих мерења, пожељно одредити и да ли се објекат греје и у складу са тим, може се адаптирати скала боја и самим тим и процене спољних температура.

Чак и уз детаљну анализу параметара за инфрацрвено испитивање, постоји вероватноћа грешке у добијању тачне дијагнозе. Уколико је зграда споља заштићена металном површином долази до негативног термалног ефекта. Мале промене термичких параметара доводе до промене у естимацији термалних мостова. Уколико постоји абнормална дистрибуција вредности емисивности, отежана је инспекција објекта. Различити материјали од којих је сачињен зид могу произвести баријере приликом радијације енергије. На пример, алуминијум производи слаб одзив емисивности, што смањује способност детектовања емисије из инфрацрвених сензора. Због тога се за овакве грађевине захтева посебна пажња приликом испитивања. За површине од метала, посебно ако су глатке, вредност емисивности је од 0.05 до 0.2.

Како је експериментима потврђено да се са великом поузданошћу објекти који су саграђени од материјала високе емисивности могу овим приступом ефикасно истражити, подразумева се да су температуре у хладном периоду на површинама објекта коректно измерене и да се могу разматрати у одређивању изолације. Како се дроном постижу висококвалитетни снимци са јаким контрастом између

различитих компонената зграде, они на оптималан начин представљају термалне процесе на згради.

Приликом детекције прозора и врата може доћи до тога да појединачни прозори или врата нису детектовани јер су само делимично видљиви на фрејму нпр. због предмета који покривају објекат. Такође уколико је стамбени објекат у непосредној близини других објеката који су видљиви на визуелном фрејму, помоћу сегментације слике они се не издвајају као део позадине, већ утичу на аутоматске прорачуне температуре фасаде и могу довести до извесних варијација у прорачунима.

Приликом детекције објеката примећено је да због косе позиције објекта, прозори зграде нису увек са савршеном прецизношћу издвојени, већ обухватају и мање околне области, јер су детектовани оквири идеално правоугаоног облика. Иако се за процене температура узимају најзаступљеније нијансе, како за саму компоненту, тако и за фасаду, овакво издвајање сегмената утиче на прорачуне температура. Оваква грешка се значајно смањује представљеним алгоритмом којим се одабирају фрејмови из видео снимка за оптималну представу објекта. Међутим, поред тога, да би се смањио утицај овакве грешке, са издвојених елемената је 10% оквирног дела уклоњено за прорачуне температуре, јер сами ободи прозора не доприносе правој представи термалних процеса на овим компонентама.

Тачност детекције објеката описује се прецизношћу која представља однос позитивно детектованих елемената и суме позитивних и погрешно позитивних детекција, као и recall-ом који представља однос позитивних детекција и збира позитивних и погрешно негативних детекција. RetinaNet је једнофазни детектор објеката за који је модел машинског учења генерисан помоћу прикупљених снимака показао знатно бољу прецизност узимајући у обзир поменуте параметре.

Једна од најзначајнијих мера тачности у компјутерској визији је IoU (Intersection over Union) којом се дефинише област преклапања између стварне границе објекта и оквира који је генерисан предвиђањем. IoU се прорачунава као однос области преклапања и области уније,  $IoU = A_o/A_u$ . Захваљујући методу којим се одабира директан снимак зграде, овај параметар је такође показао високу прецизност од приближно 0.83.


Од великог значаја је разматрање грешке приликом прорачуна температура области на грађевини. Спровођењем наизменичних стандардних инфрацрвених мерења, добијена је стандардна варијација измерене температуре фасаде зграде од 2.55 °C, која је уведена у процене разлика у температури ради побољшања класификације објеката, што је детаљније описано у поглављу 5.

Како би се једноставније утврдила термална својства издвојених области приликом њиховог упоређивања, принципом раздвајања кластера KMeans методом издвојени су најзначајнији центри елемента и упоређени су са скалом боја, у циљу да се сви појединачни делови класификују као хладне или као топле области.


## ПОГЛАВЉЕ 4

### 4.1 Експериментални резултати


Инфрацрвеним сликама су представљени различити температурни подаци. Разлике у температурној расподели указују на критичне регионе у смислу енергетских перформанси фасаде. На примеру приказаном на слици 16 је један мањи део фасаде зграде. Може се приметити утицај боје фасаде на термалну слику, тј. на детектоване температуре фасаде. На слици 17 представљени су издвојени прозори, као и њихова редукована форма, ради побољшања тачности.



Слика 16 Издвојени део фасаде



(a)




(b)

Слика 17 Издвојени прозори и корекције ради побољшања тачности прорачуна

Добијају се карактеристичне наранџасте и лила нијансе температурне представе са RGB вредностима (230, 80, 27), (185,9, 133) и (215, 48, 55) и прорачуната је просечна температура 14,9 °C за први прозор. За други прозор су добијене вредности представника боја (184, 4, 129), (229, 91, 19) и (219, 62, 55). Површине прозора су детектоване као светле.

За карактеристичне RGB представе фасаде, добијене су вредности (98, 0, 149), (131, 1, 151) и (64, 1, 144) и прорачуната је вредност температуре од 11.9 °C, па су добијене процењене варијације температуре 3.2 °C и 3 °C. Уколико се дода варијанса, максимално одступање износи 5.8 °C. Област фасаде детектована је као хладна. Прорачуном се добија да више од пола површине чине прозори у односу на укупну површину и може се сматрати да је значајан утицај добијених разлика у процењеним температурама.

Исход алгоритамске анализе даје да су присутни већи топлотни губици на прозорима. Коришћењем конволуционе мреже утврђено је присуство термалних мостова на фасади ове зграде.

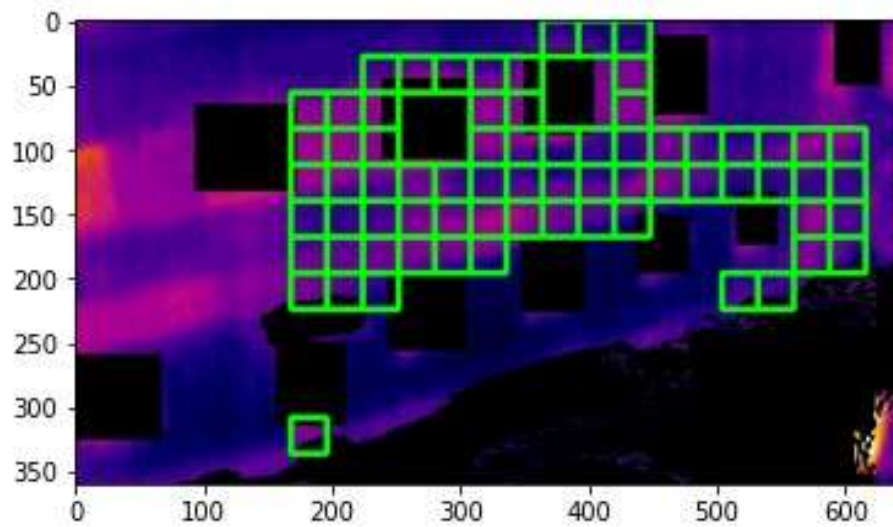


Слика 18 Детектовани и издвојени прозори зграде

Наредне табеле представљају резултате након програмских итерација за фрејм представљен на слици 18 [145]. На овој слици дат је целовитији приказ исте зграде као и на претходном фрејму. Излазне карактеристичне боје за први прозор биле су (96, 4, 149), (72, 2, 135) и (51, 2, 130), а за други прозор (128, 1, 150), (192, 19, 124) и (199, 25, 123) и за остале прозоре пронађене су сличне карактеристике. Табела приказује прорачунате температуре за сваки сегментовани прозор и за фасаду у првој колони и температурне разлике између ове две компоненте као и класификацију као тамне или светле.


Табела 3 Измерене температуре елемената зграде и њихова разлика

	<i>Прозор 1</i>	<i>Прозор 2</i>	<i>Прозор 3</i>	<i>Прозор 4</i>	<i>Прозор 5</i>	<i>Прозор 6</i>	<i>Прозор 7</i>	<i>Фасада</i>
T	11.5	13.5	11.8	11.5	15.0	13.6	12.8	12.1
$ T_f - T  + \sigma$	3.2	4	2.9	3.2	5.5	4.1	3.3	
пиксели	1800	1911	1221	2352	2750	3520	858	58016
светлост	хладна	топла	топла	топла	топла	топла	топла/хладна	хладна



Слика 19 Детектовани термални мостови [145]

На слици 19 представљен је резултат детекције термалних мостова на фасади помоћу модела заснованог на CNN мрежи и алгоритма клизећег прозора, чиме се јасно истичу региони који указују на више температуре од осталих области фасаде, а који са визуелног фрејма нису уочљиви.



Слика 20 Детектовани прозори и издвојена позадина за зграду

За фрејм који приказује спољашњост зграде на слици 20 добијају се карактеристичне боје (224, 67, 26), (191, 6, 133) и (221, 62, 33) и број пиксела од 40768. Наредна табела приказује боје које су добијене за појединачне сегменте. Као коначан резултат добија се да нема значајних разлика између елемената и може се закључити да је објекат добро изолован.

Табела 4 Најчешће боје сегмената


<i>Фасада</i>	(224 , 67, 26), (191, 6, 133), (221, 62, 33)
<i>Прозор1</i>	(218 , 51, 61), (215, 42, 87), (217, 49, 66)
<i>Прозор2</i>	(216 , 50, 62), (230, 74, 26), (224, 62, 47)
<i>Прозор3</i>	(220, 62, 33), (227, 69, 30), (211, 40, 85)
<i>Прозор4</i>	(230 , 82, 18), (221, 61, 47), (222, 72, 22)
<i>Прозор5</i>	(232 , 95, 1), (218, 58, 36), (223, 70, 26)

Табела 5 Процењене температуре појединачних сегмената, пронађене нијансе са инфрацрвених слика и разлика температура за суседне елементе

	<i>Прозор1</i>	<i>Прозор 2</i>	<i>Прозор3</i>	<i>Прозор 4</i>	<i>Прозор 5</i>	<i>Фасада</i>
T	14.8	15.4	15.5	15.8	16.1	15.2
$ T_f - T  + \sigma$	3.3	2.8	2.9	3.2	3.5	
пиксели	704	1080	512	960	595	40768
светлост	топле	топле	топле	топле	топле	топле/хладне

Ова табела представља резултате обраде свих сегментираних области зграде помоћу чијих параметара је извршена класификација.





Слика 21 Сегмент зграде

На овим паралелним снимцима је један сегмент исте зграде на којем су детектована три прозора. На једном прозору је затворена ролетна, што указује на ниже температуре. На визуелној слици се уочава да је зграда новије грађе. Део фасаде који је од цигле као и балкон са стакленом површином има више

температуре, али у овом случају виша температура је карактеристика овог материјала да се у њему задржава топлота, а не одраз губитака топлоте.

У наредним табелама су приказани прорачунати параметри.

Табела 6 Најзаступљеније боје за појединачне компоненте зграде

	RGB
<i>Фасада</i>	(233 , 91, 7), (190, 9, 138), (217, 58, 36)
<i>Прозор 1</i>	(229, 87, 11), (219, 61, 32), (205, 34, 68)
<i>Прозор 2</i>	(254, 194, 10), (251, 180, 10), (242, 143, 0)
<i>Прозор 3</i>	(187 , 9, 131), (205, 26, 84), (219, 44, 83)

Табела 7 Прорачунате температуре елемената, нијансе компоненте и разлика температура

	<i>Прозор 1</i>	<i>Прозор 2</i>	<i>Прозор 3</i>	<i>фасада</i>
T	15.6	17,7	14.5	15.3
$ T_f - T + \sigma $	2.9	5	3.4	
пиксели	2280	4392	704	45472
светлост	светла	светла	светла	светла/хладна

Као резултат и овај сегмент зграде са слике 21 је класификован као добро изолован.



Слика 22 Издвојени мањи објекат са детектована три прозора и врата

За фасаду објекта на слици 22 пронађене су карактеристичне RGB вредности (232, 93, 0), (247, 176, 6) и (232, 85, 5) и процењена је просечна температура од 16,7°C.

За први прозор процењена је просечна температура од 17.8 °C, што представља значајне топлотне губитке, а карактеристичне нијансе су (246, 177, 0), (246, 193, 3) и (250, 172, 2). За врата добијене RGB вредности су (244, 179, 1), (243, 132, 1) и (244, 153, 0) а прорачуната температуре је 17.3 °C. За други прозор процењена је температуре од чак 18.4 °C и издвојени тонови су (250, 200, 7), (247, 280, 3) и (249,

228, 51). За трећи прозор просечна израчуната температуре је  $17.4\text{ }^{\circ}\text{C}$  и издвојене нијансе су (246, 176, 0), (245, 166, 1) и (249, 154, 2). То указује на мале разлике, када су у питању топлотни губици на објекту и узимајући у обзир релативно високе процењене температуре по површини објекта, може се претпоставити да је овај објекат слабо изолован.

За вредност температуре крова, добија се  $17.8\text{ }^{\circ}\text{C}$  (RGB (227, 93, 0), (245, 192, 2) и (253, 224, 62)).

Одступање у температуре између крова и фасаде је  $1.1\text{ }^{\circ}\text{C}$ . Максимално температурно одступање између прозора и фасаде је  $1.7\text{ }^{\circ}\text{C}$ . Како су детектоване температуре високе, то указује на лошу изолацију.

## ПОГЛАВЉЕ 5

### 5.1 Поузданост дијагнозе термалних губитака

Параметри које је потребно размотрити приликом инспекције и који утичу на тачност мерења и на њихову интерпретацију су карактеристике термалне камере, као што су термална резолуција и геометријска резолуција видног поља. Мали покрети беспилотне летелице и визуелне препреке на које се наилази приликом снимања, ометају генерисање квалитетних слика. Термална резолуција и оштрина термограмске слике зависе од броја сензора за инфрацрвену радијацију.

Спољни фактори утичу на приступачност грађевинских конструкција за које се врши инспекција. Објекти из окружења могу ограничити видљивост поља у току скупљања података, као што су пролазници или дрвеће. Пред тога, због различитих препрека у окружењу, као и утврђених правила за навигацију летелице, ограничена је могућност навођења висине и удаљености уређаја од објеката. Посебним алгоритмима могу се планирати и путање лета беспилотне летелице. Догађаји као што су отворени прозори или врата утичу на некоректну представу топлотних губитака. Може се сматрати да су овакве појаве ретке и да би се предупредиле грешке у мерењима, потребно је званично обавестити становнике о мерењима.

На поузданост термалне инспекције утичу и карактеристике структуре и материјали објекта, однос површина прозора и фасаде, грејни систем и вентилација. Значајни параметри који утичу на исход мерења су емисивност, растојање од камере до објекта, рефлексија, као и параметри окружења као што су температура и релативна влажност ваздуха.

### 5.2 Утицај временских фактора на мерења

Термограмска мерења је потребно извршити у хладном зимском периоду када се објекти греју, да би се испитало продирање топлотне масе из топлијег унутрашњег простора ка хладнијем спољашњем простору. Јачина ветра утиче на топлотне процесе на површини зграде и може условити варијације при мерењима температура површине објекта. Утицај сунчевог зрачења може довести до промена у површинским температурама, чак и дуже време након изложености зрачењу. Поузданији резултати се стога добијају уколико се инфрацрвена мерења врше у раним јутарњим часовима. Један од важних аспеката у испитивању стања грађевине је организовање снимања пре подне јер сунчева светлост још увек не загрева интензивно зграде и омогућује довољно светлости за снимање објекта као и безбедну навигацију уређаја. Појава кише има негативан утицај на мерења, јер


проузрокује хлађење површина материјала. Поред тога, присуство водене паре у атмосфери доводи до слабљења сигнала који стиже до мерног уређаја и због тога се параметар влажности ваздуха разматра прорачуном трансмисивности атмосфере.

### 5.3 Утицај материјала зграде на мерења

Велики изазов у термографској евалуацији зграде представљају бројне врсте материјала и архитектура зграда. Различити материјали се користе у конструкцији фасада зграда, као што су метали челик и алуминијум као и стакло, које је често у употреби за изградњу пословних објеката. Измерене температуре зграда зависе од специфичних карактеристика материјала од којих је зграда направљена. Експериментима који су обављени теренским инфрацрвеним уређајем добијене су термалне слике које показују одлике различитих материјала фасада и испољавање термалних процеса у складу са материјалима.

Материјали од којих је зграда саграђена одликују се различитом емисивношћу, која се на мерном инструменту може адаптирати. Емисивност представља физичку карактеристику материјала која описује колико ефективно материјал може да преноси енергију у виду термалне радијације. Коефицијент емисивности се одређује као однос радијативне енергије са површине објекта и енергије ослобођене са теоријског црног тела на истој температури и таласној дужини и креће се у опсегу од 0 до 1. Приликом мерења теренском термографијом, потребно је подесити емисивност, у складу са материјалом испитиваног објекта. Различита подешавања термалне емисивности производе другачије термалне слике објеката за исте временске услове.

Уколико се снима зграда која је споља од метала, добијени инфрацрвени снимци могу указивати на велике губитке топлоте, иако су уочљиве високе температуре најчешће узрок присуства рефлексије. Препоручују су поновљена мерења за овакве објекте, јер се захтевају комплексније процедуре у процени њихове емисивности, посебно ако је коефицијент емисивности мали. Објекти из непосредног окружења утичу да инфрацрвена мерења јер приказују и термалне процесе који потичу од других извора.



Слика 23 Ефекат емисивности

Приликом прикупљања података беспилотном летелицом, пошто су снимљени бројни објекти, емисивност није могла бити динамично адаптирана, као што је пракса у устаљеним теренским мерењима. Ипак, експерименти су показали да поступак у којем је претпоставка да је генерални коефицијент емисивности  $\epsilon = 0.95$  нема значајног утицаја на валидност инфрацрвених снимака, јер је већина испитиваних објеката изграђена од цигала и бетона који се карактеришу високом емисивношћу.

Инспекција зграда исте грађевине може бити поновљена, да би се детектовале промене у измереним температурама под различитим условима. При поновљеним мерењима, може се догодити да су добијена различита стања за сличне спољне услове.

Како временски фактори утичу на термалну инспекцију зграда, обављена су поновљена мерења за објекте изграђене од различитих материјала, да би се утврдиле варијације условљене измењеним временским условима. Употребљен је теренски инфрацрвени мерни уређај за прикупљање података у различитим временским условима и у различито доба дана. Инфрацрвена мерења су подразумевала калибрацију коефицијента емисивности и прорачун радијативне, рефлектоване и атмосферске енергије. Настојање у овој анализи, било је да се идентификују осетљиви параметри у термографској инспекцији, који утичу на остварене приказе објеката и да се квантитативно испита њихово испољавање на прорачуне енергетске перформансе зграде. Испитиван је утицај мањих варијација спољних услова на исход мерења. Инфрацрвене слике су сакупљене при препорученим временским условима за ниже спољне температуре.

Приликом квантитативне анализе, одређени параметри се морају дефинисати, да би се осигурала тачност у току мерења, а то су поред емисивности материјала и рефлектоване температуре, ефективна температура околине, коефицијент трансмисије атмосфере, релативна влажност ваздуха и растојање мерног инструмента од објекта.

Теренска мерења су захтевала адаптацију коефицијента емисивности за различите материјале зграда користећи електричну траку и очитане су површинске температуре са инфрацрвеног мерног уређаја за кориговане вредности емисивности. Рефлектована температура је прорачуната као просечна вредност приказаних температура на комаду савијене алуминијумске фолије, као што је описано у експериментима обављеним у [40]. Трансмисивност ваздуха утиче на смањење пренесеног сигнала кроз атмосферу и зависи од атмосферске влажности ваздуха и од растојања између објекта и мерног уређаја. Коефицијент трансмисије је утврђен према налазима [62]. Процедура мерења обухватала је не само подешавање емисивности и мерење рефлектоване температуре, већ и бележење влажности ваздуха и растојања до објекта у моменту мерења. Из прикупљених података свих мерења, одређен је проценат емитоване, рефлектоване и атмосферске енергије у односу на прорачунату тоталну радијативну енергију. Настојало се да се разуме како термалне слике за исте грађевинске објекте зависе од различитих спољних температура и различитих доба дана. Спољне температуре су се кретале у опсегу од  $-1^{\circ}\text{C}$  до  $11^{\circ}\text{C}$ .

Поновљена мерења показују да рефлектована енергија представља мали удео у радијативној енергији објекта, пре свега због високог коефицијента емисивности који је уобичајено  $\epsilon > 0.95$  и стога се рефлексија може занемарити када се избегне соларна радијација. Показало се да се утицај атмосфере може занемарити, јер су резултати експеримента дали коефицијент трансмисије приближно  $\tau = 0.99$  за мала растојања између мерног уређаја и објекта, чак и у случају веће влажности ваздуха. Уколико се мерења спроводе са мањих растојања, радијативна енергија зграде одређена је пре свега површинским температурама и коефицијентом емисивности. Наредне табеле представљају добијене резултате мерења.

Табела 8 Измерена радијативна и рефлектована енергија за различите материјале и енергија из атмосфере

<b>31.3.2023, T = 8°C, влажност ваздуха 76%, ветар 8km/h</b>	<b>Метал</b>	<b>Мермер</b>	<b>Пластика</b>	<b>Цигла</b>	<b>Блок</b>
Емитована енергија [ $\text{W}/\text{m}^2$ ]	385.4	387.5	382.7	356.1	340.7
Рефлектована енергија [ $\text{W}/\text{m}^2$ ]	3.8	3.7	3.8	19	46.8
Атмосферска енергија [ $\text{W}/\text{m}^2$ ]	4.4	4.4	4.4	4.4	4.4
Тотална радијативна енергија [ $\text{W}/\text{m}^2$ ]	388.95	390.9	386.3	375	387.25
Процентуална емитована енергија [%]	99	99	99	95	88




Табела 9 Измерене вредности радијативне, рефлектоване енергије за фасаду од метала, пластике и цигле и енергија из атмосфере


<b>1.4.2023, T = 8°C, влажност ваздуха 76%, ветар 26km/h</b>	<b>метал</b>	<b>пластика</b>	<b>цигла</b>
Емитована енергија [W/m <sup>2</sup> ]	371.7	363.9	336.1
Рефлектована енергија [W/m <sup>2</sup> ]	3.7	3.7	24.7
Атмосферска енергија [W/m <sup>2</sup> ]	4.3	4.3	4.3
Тотална радијативна енергија [W/m <sup>2</sup> ]	375.2	367.5	360.8
Процентуална емитована енергија [%]	99	99	93

Пронађене су више температуре за зграде изграђене од метала, пластике и цигле без видних разлика у измереном сигналу и контраста у сликама. Приликом поновљених мерења, мале варијације коефицијента емисивности су регистроване за исте грађевинске објекте при различитим спољним условима. Показало се да је добијена радијативна енергија за исте грађевине и при другачијим спољним условима имала приближно исте вредности. Утицај рефлексије се уочава код материјала са мањом емисивношћу.


Подешавање аутоматизованих визуелних сензора којима се сакупљају инфрацрвене слике у условима променљивих временских услова је изазов у поређењу са класичним методама. Ради конзистентности резултата, развијена је методологија за поређење скупа примерака инфрацрвених слика за исте објекте при варијацији спољних услова, као што су температура, влажност ваздуха и сунчево зрачење.



4.3.2023  
7:15, 2 °C




31.3.2023  
8:30, 11 °C




1.4.2023  
7:00, 8 °C


Фасада од цигле



4.3.2023  
7:15, 2 °C




6.3.2023  
20:00, 10 °C



28.3.2023  
9:30, 3 °C




31.3.2023  
8:30, 11 °C




1.4.2023  
7:00, 8 °C


Фасада од пластике




28.2.2023  
9:00, -1 °C




4.3.2023  
7:15, 2 °C




5.3.2023  
8:00, 2 °C



6.3.2023  
20:00, 10 °C



28.3.2023  
9:30, 3 °C



31.3.2023  
8:30, 11 °C

Блок фасада

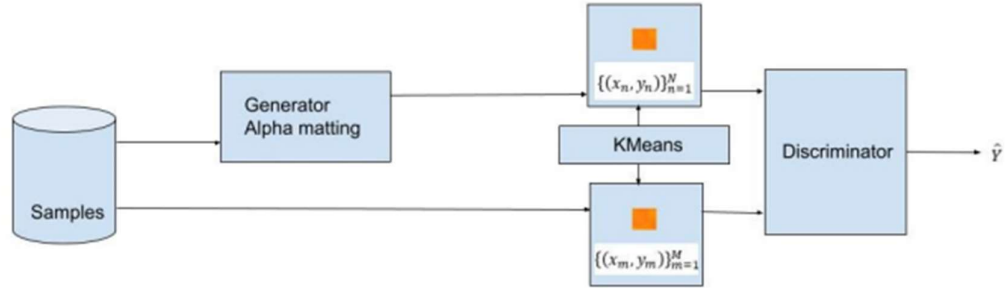
Слика 24 Поновљена термална мерења за зграде од различитих материјала

На основу приказаних табела може се закључити да су за фасаду од цигле и пластике измерене температуре при различитим временским условима биле више, што одражава специфичне карактеристике ових материјала. На приказаној слици низ снимака за трећу зграду показује различите инфрацрвене слике и бољи контраст је остварен за ниже спољне температуре. Са променом спољних услова, емисивност ове зграде је варирала у опсегу од 0.78 до 0.88, што представља већи скок у односу на остале објекте где је одступање емисивности било приближно  $\Delta \varepsilon \approx 0.02$ .

Принцип валидације термалних снимака заснован је на логици GAN мреже, као што је представљено у објављеном артикулу часописа *Eng*, 2023. Издвојена је слика са јаким контрастом, за коју се претпоставља да је коректна и генерисана је нова слика преклапањем референтне слике са наизменичним сликама из сакупљених примерака, а затим је генерисана слика упоређена са наредном сликом из скупа. Примењена метода користи GAN структуру, која укључује дискриминатор, који пореди слике и доноси одлуке о њиховој сличности. Изразите температурне промене раздвојене су термалним ивицама и контуре региона са противречним топлотним губицима могу се издвојити коришћењем K- Means алгоритма. На тај начин се пиксели инфрацрвене слике класификују као хладне и топле зоне и сегментују се термални региони.

Помоћу KMeans алгоритма груписани су пиксели, чије су RGB вредности најближе пронађеним центроидима и обојени су бојама које одговарају центроидима, што омогућује ефектно издвајање термалних карактеристика објекта. То омогућује утврђивање региона са већим топлотним губицима и ове области су сачуване у виду низа координата које одговарају детектованим светлим бојама. Дискриминатор мреже пореди сачуване низове координата и даје предикцију да ли су улазне слике сличне, тј. да ли су области са изразитим губицима на сличним позицијама на снимцима. Узимајућу у обзир узорке инфрацрвених слика грађевинских објеката, детектоване области са већим температурама су употребљене у процесу тренинга дискриминатора, да би се обезбедила предикција.

Дискриминатор мреже предвиђа тачност улазних слика поредећи означене регионе са значајнијим топлотним губицима на преклопљеној слици и наредној слици из скупа примерака. Наредна слика показује механизам адаптиране GAN мреже.



Слика 25 Шематски приказ GAN за поређење термалних слика [124]

Поједини материјали показују веће скокове у измереним температурама за незнатно другачије временске услове и због тога може бити комплексно донети одлуке о критичним областима на грађевинском објекту у смислу енергетске ефикасности. Помоћу GAN мреже побољшава се контраст инфрацрвених слика што олакшава издвајање региона са већим температурама. Након обраде улазних слика KMeans методом, бинарне вредности које представљају позиције области топлотних губитака су упоређене у мрежи дискриминатора.

Принцип мреже за проналажење одговарајућих инфрацрвених слика заснива се на подударачу снимка одређеног објекта и одабраног референтног стања и процесирањем просторних параметара комбиноване и стварне слике. Функција дискриминатора који на излазу даје процентуалну вредност подударача аргумената, може се представити наредном формулом:

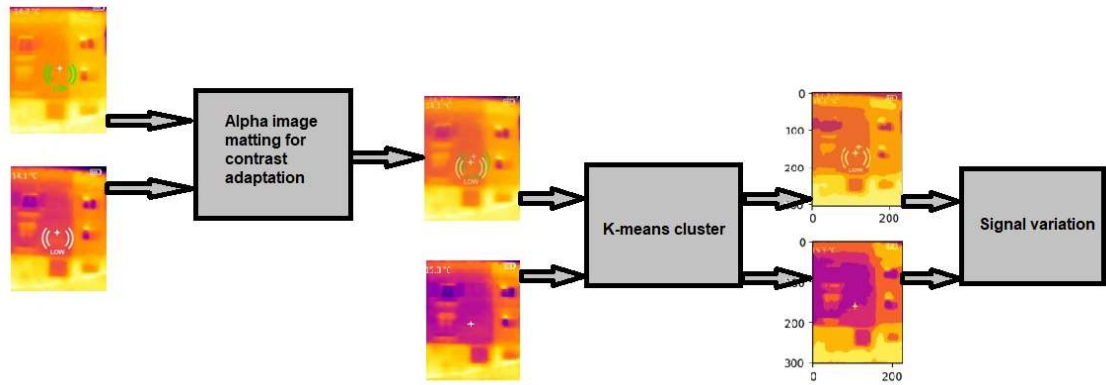
$$\max_{i \in [1, N]} I_{curr} \cdot I_{acc} - I_{prev} = \Delta I_{max} \quad (17)$$

где  $N$  представља укупан број узорака за исту грађевину.

На овај начин је омогућено да се процени вероватноћа исправности термалних узорака за испитиване грађевинске објекте на основу различитих мерних података. Како би се постигла прецизнија дијагноза квалитета изолације за различите инфрацрвене слике, селектују се слике са већом вредношћу предикције на излазу.

Генерисана слика у овом случају представља комбиновану слику из скупа са издвојеном референтном сликом и ова операција је позната као Alpha matting [33], где  $\alpha = 0.5$  означава подједнаки удео обе улазне слике  $I'$  и  $I''$ .

$$I_{cmb} = 0.5 * I' + 0.5 * I'' \quad (18)$$




Слика 26 Операција преклапања и кластеризовања инфрацрвених слика објеката

На улазу дискриминатора су дводимензионални низови који одговарају координатама пиксела у регионима захваћеним термалним губицима, а очекивана вредност представља предикцију тачности инфрацрвене слике. Улазни низ има форму  $X = \{(x_j, y_j)\}_{j=1}^n$ , где је  $n$  број пиксела са регионима регистрованим са вишим температурама. Предикција вероватноће на излазу је у опсегу од 0 до 1.

Одређивањем нивоа светлости и селекцијом специфичних боја палете које одговарају вишим температурама, прорачунате су еуклидијске дистанце да би се издвојио кластер високих температура. Да би се могле подударити ознаке региона који представљају термалне губитке, укључена је функција entropy cost у дискриминатору. Први слој мреже дискриминатора садржи 32 улаза са активационом функцијом relu и he uniform иницијализатор кернела. Други слој мреже састоји се од 16 улаза са активационом функцијом relu и he uniform иницијализатором кернела. Трећи слој је dense са једном улазном вредношћу и активационом sigmoid. Модел је компајлиран користећи binary cross entropy и оптимизацију Adam.

Наредни график представља пример предвиђених вредности подударања низа инфрацрвених слика. Уочава се да је добијена вероватноћа у опсегу од 0.7 до 0.95.



Слика 27 Вероватноћа подударња узорака [124]

Уколико је емисивност мала, измерене температуре варирају и проузрокују разлике у радијативној енергији. При веома ниским температурама, измерене површинске температуре су ниже резултујући у бољем контрасту између елемената и омогућујући да се лакше издвоје према протоку топлоте. При порасту температура детектују се више температуре и теже је издвојити елементе према топлотним губицима, јер се сличне вредности детектују за читав објекат и поред разлика у унутрашњој и спољашњој температури. Више температуре су измерене уколико су инфрацрвене слике урађене увече.


Измерене температуре за различите грађевинске објекте обрађене су статистички да би се утврдила средња вредност измерене температуре и емпиријска стандардна девијација. Ови резултати су помогли у поређењу процена површинских температура објеката које се добијају развијеним алгоритмом и потврђују коректност предвиђених температура из резултата исраживања. Средња вредност температуре из свих регистрованих температура зграде је:

$$T_m = \frac{\sum_{i=1}^n T_i}{n} \approx 11.5 \text{ } ^\circ\text{C} \quad (19)$$

где  $n$  представља број мерења а  $T_i$  је измерена температура за један објекат. Варијанса температуре добијена је као одступање од средње вредности. Емпиријска стандардна варијација прорачуната је као квадратно одступање, чиме се узимају у обзир већа одступања:

$$s = \sqrt{\frac{\sum_{i=1}^n (T_i - T_m)^2}{n}} \approx 2.55 \text{ } ^\circ\text{C} \quad (20)$$

Емпиријска стандардна девијација укључена је у прорачуне представљеног модела за класификацију зграда, чиме се урачунала грешка регистрованих температура. Наредна слика приказује криву нормалне расподеле на основу измерене температуре објеката.



Слика 28 Гаусова дистрибуција температуре


#### 5.4 Утицај спољних фактора на мерење

На представу термалних процеса једног објекта утичу позиција мерног инструмента и његово растојање од објекта. Препоручује се да се термална мерења обављају са мањег растојања. Услед динамичког померања инструмента, дистанца није у сваком моменту предвидљива.

На појединачним фрејмовима је уочљиво, да на добијене температурне карактеристике зграде утиче и боја фасаде, као и сунчева светлост.


У току прикупљања података овом методом, не могу се контролисати догађаји из околине, као што су затворене ролетне на прозорима које утичу на знатно ниже измерене температуре, или отворени прозори који би погрешно указивали на значајно високе топлотне губитке, као и пешаци у околини и други објекти који се налазе у првом плану. Наредни фрејмови приказују разлике у измереним температурама за исти објекат за различите углове снимања, и једну особу у близини објекта.

Наредни график представља пример пада процењене радијативне енергије на основу добијених температура, а у складу са приказаним бојама на инфрацрвеним сликама, посматрајући секвенцијалне фрејмове са истом зградом који су снимљени под благо различитим угловима.



Слика 29 Варијација радијативне енергије за sukcesивне снимке објекта [145]





Слика 30 Ефекат угла снимања

Други различити фактори као што су велики балкони, који могу бити направљени од различитих материјала, могу заклонити површине зграде од интереса у току инспекције и утицати на ефективност мерења. У току испитивања могу се издвојити вредне информације и у зависности од фреквенције одабирања видео сигнала, може се остварити велики број термалних слика. Међутим, нису све слике повољне за анализу због угла и прекривања области објекта. Због тога је значајно алгоритамски селектовати најповољније термалне слике за класификацију. Како би се програмски и аутоматски добила детаљна анализа стања објекта користећи ову методу, потребно је да се снимање врши што је могуће ближе објекту избегавајући околне зграде.

## ПОГЛАВЉЕ 6

### 6.1 Поређење са другим техникама

Визуелни подаци који се добијају инспекцијом зграда беспилотном летелицом дају сазнања о актуелном стању зграде и представљају извор информација за препознавање неадекватне изолације зграда. Уколико је дијагностикована неодговарајућа изолација, детаљнији експерименти као што је понављање мерења, могу поткрепити налазе добијене проценама алгоритма.

Ради поређења урађени су додатни експерименти користећи механизме који су примењени у скоријој литератури: Laplacian of Gaussian blob детектор, Random Forest, KMeans и сегментација региона од интереса (ROI). Laplacian of Gaussian методом локализују се тачке које представљају минимуме, односно најхладније регионе на инфрацрвеној слици. У поређењу са осталим алгоритмима, овај метод је био најспорији и локализација хладнијих подручја не омогућују довољно прецизну анализу термалне ефикасности објеката и карактеризацију типа топлотних губитака. Класификација помоћу Random Forest метода омогућила је прецизно издвајање карактеристичних боја инфрацрвених слика и њихово процентуално прорачунавање и због тога је она погодна за утврђивање површина које су захваћене топлотним губицима. KMeans груписање је брз начин за сегментирање региона у сликама захваћеним јачим губицима топлоте и често се примењује у анализи термалних слика. Региони од интереса (ROI) се могу издвојити применом филтара који издвајају светлије и тамније области на инфрацрвеној слици или издвајањем целокупних области на основу нијанси. Заједничко за наведене методе је да не омогућују доношење закључака о стању изолације зграде, већ искључиво истичу области са вишим и нижим температурама. Стога у поређењу са поменутиим приступима нова развијена метода даје свеобухватну термалну анализу зграде.

### 6.2 Будући трендови

У зависности од грејања зграда, унутрашња температура која зависи од подешавања грејног система, може бити виша или нижа, па се у складу са тим добијају другачији прикази термалних карактеристика објеката. Тачност резултата спољних мерења, може бити поткрепљена праћењем температура на различитим нивоима зграда помоћу сензора којима се детектује температура и влажност ваздуха у јединици времена и у одређеном простору. Подаци са сензора се могу сакупити у централном уређају, одакле се могу послати одговарајућим сервисима. Просторије са сниженом температуром и са повишеном влажношћу ваздуха се на тај начин брзо могу уочити, ради поткрепљења спољашње дијагноза стања изолације зграде. Употребом мерних уређаја и паметних сензора, инсталираних у зградама, могу се

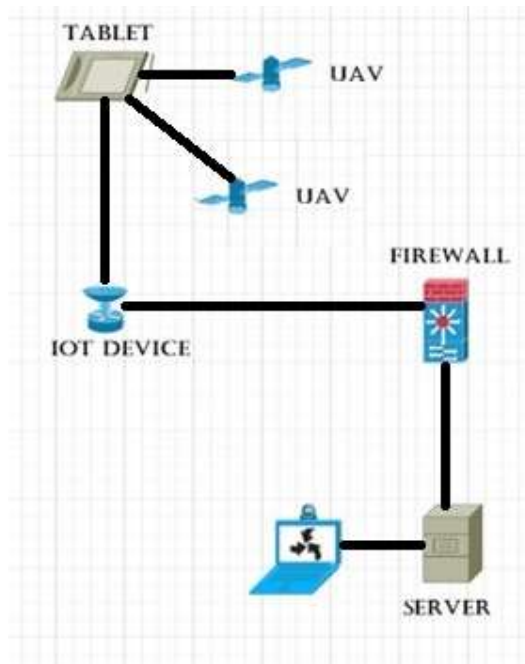
сакупити велике количине података, који могу помоћи у детекцији и разумевању узорака аномалија.

Ова метода прикупљања података и њихове анализе је недеструктивна, па се мерења могу поновити како би се пронашли недостаци. Оптимални систем за надгледање исправности зграда, може обезбедити обраду података и извештаје о исправности у реалном времену. Овакав концепт захтева додатне уређаје који могу обезбедити комуникацију већег броја беспилотних летелица са сервисима. Модерни стандарди који се односе на квалитет живота захтевају побољшања у напредном коришћењу ресурса и у смањењу негативних ефеката на околину, што је довело до иновација у подручју информационих и комуникационих технологија. Напредан начин за мониторинг сајтова укључује IoT (Internet of Things) платформе и технике компјутерске визије, чиме се брже могу обрадити термалне слике. За овакав систем потребно је обезбедити мрежну повезаност, укључујући сигурносне мере, како би се подаци могли доставити до захтеваних сервиса да би се обрадили. Сигурносни протоколи се могу интегрисати у новије архитектуре мобилних система ради ефикасног преноса прикупљених података.

Концепт IoT представља комуникацију између уређаја и односи се на беспилотне летелице са базном станицом. IoT технологије омогућавају повезаност беспилотне летелице помоћу бежичне или мобилне мреже, чиме се видео записи преносе до сервиса на којима се алгоритамски обрађују подаци. Вештачка интелигенција има способност да исфилтрира значајне информације из прикупљених података добијених дроном и оваквом аутоматизацијом може се обезбедити анализа записа инспекције зграда у реалном времену као и надгледање читавог процеса класификације грађевинских објеката и њених сегмената.

Стратегије IoT ће се у будућности користити за надгледање изградње и стања грађевинских објеката. Употреба беспилотних летелица у грађевинској индустрији је економично решење због флексибилности маневара, чак и на опаснијим локацијама. Методе машинског учења могу аутоматски идентификовати оштећења, чиме се значајно убрзава процес обраде обимне количине података, наизменичним експерименталним итерацијама, користећи вишеструке сетове података.

Модерне технологије обезбеђују повезаност са различитим сервисима, спровођење обраде података, сједињење података различитих извора и анализу велике количине података путем вештачке интелигенције. Такође, обезбеђена је оптимизација платформи због процесорске моћи IoT уређаја. Увођењем система за надгледање енергетске ефикасности и стратегија моделирања, унапређује се доношење одлука са циљем да се смањи потрошња енергије и да се постигне одржива енергетска ефикасност.



Слика 31 Шематска представа за IoT комуникацију

Помоћу интелигентног управљања енергетским системима користећи вештачку интелигенцију, инфраструктура може аутоматски реаговати на губитке и могу се препознати одступања од нормалног стања [17]. Услед убрзаног развоја сензорских технологија, омогућено је континуирано праћење унутрашњег простора. Визуелне и термалне слике могу пратити лица присутних у простору и препознати да ли су особе задовољне температуром и помоћу сензора се могу адаптирати системи за терморегулацију [85].

## ЗАКЉУЧАК

Обезбеђивање термалне ефикасности зграда је један од најважних предуслова за очување енергије. Ова дисертација је представила систематичну методологију за ефикасну анализу зграда засновану на вештачкој интелигенцији, која за уштеду енергије и здравије окружење има велики потенцијал практичне примене. Размотрена је могућност детекције недовољне изолације користећи технологију инфрацрвених мерења за велики број различитих типова грађевинских објеката ради побољшања структуре изолације. Ефикасно удаљено прикупљање података остварено је помоћу беспилотне летелице опремљене оптичком и инфрацрвеном камером.

Последњих година са развојем напредних метода заснованих на обучавању неуралних мрежа, омогућена је брза обрада термалних слика, како би се детектовале области за које се може унапредити изолација. Метод за дијагнозу стања изолације грађевинских објеката визуелно издваја компоненте објекта користећи алгоритме за детекцију објеката на визуелним снимцима и сегментацију термалних слика. Ефикасним методама компјутерске визије омогућена је детаљна анализа елемената и доношење закључака о термалном понашању зграде.

Представљеним методом се са великом ефикасношћу може обрадити велики број визуелних података за различите пословне и стамбене објекте, што би користећи уобичајене методе било временски и финансијски захтевно. Додатно убрзавање процеса инспекције постигнуто је употребом беспилотне летелице која може снимити читаву насеља и сакупити вредне податке за глобалну инспекцију грађевинских објеката у локалним областима. Беспилотном летелицом се могу снимити и тешко приступачна подручја, а посебно је погодна за инспекцију високих зграда, јер су омогућена инфрацрвена мерења и визуелна анализа из свих перспектива. Знатно олакшање термалне анализе и укупне енергетске ефикасности грађевинских објеката постигнуто је и тиме што су на снимцима беспилотном летелицом објекти у целости видљиви, што класичне теренске методе често не омогућују.

Иако су експерименти са беспилотном летелицом и употреба вештачке интелигенције у обради сакупљених података веома актуелан предмет истраживања у многим земљама света, ипак већи део литературе помиње њихову уопштenu примену и конкретне апликације су ограничене на генерисање термалних тродимензионалних модела зграда мапирањем тачака из визуелних и термалних података, истраживања унутрашњости простора и на детекцију оштећења на спољашњости објеката методама надгледаног учења.

Представљена методологија омогућује детаљну анализу компонената грађевинских објеката на основу прорачунатих температура и њиховог односа и свеукупну евалуацију термалних карактеристика. Користећи модел RetinaNet заснован на ResNet структури за детекцију објеката тренирањем мреже методом

надгледаног учења издвојени су елементи грађевине да би се размотриле њихове појединачне температуре и температурна одступања елемената. У ту сврху креирани сет података је програмским путем означен класамa предмета за тренирање неуралне мреже како би се омогућила предикција категорија компонената. Детекција објеката је омогућила да се лоцирани објекти даље испитају, јер су идентификоване њихове координате. Повољност беспилотне летелице са две камере које снимају паралелно из истог угла је искоришћена путем добијене информације о објектима из визуелног фрејма.

Метода дубоког учења за издвајање сцене је примењена за издвајање целина у оквиру снимака са беспилотне летелице, како би се размотриле искључиво области које садрже важну информацију за категоризацију термалних карактеристика. Применом GAN за упоређивање варијација температурног мерења, обухваћено је разматрање осетљивости термалних слика на временске услове, као што су сунчана радијација, облачност и влажност ваздуха, да би се унапредила поузданост мерења.

Развијени оригинални приступ за комплетну анализу термалног понашања грађевинских објеката путем вештачке интелигенције даје детаљне податке о природи топлотних губитака и јасну процену стања изолације и стога је од велике предности у односу на остале механизме, којима се пре свега локализују региони са вишим температурама и аномалијама. Применом алгоритама компјутерске визије на обрађене слике утврђено је да ли је већи проценат захваћености објекта топлотним губицима. Дијагноза функционалности зграда са становишта енергетске отпорности унапређена је аутоматском обрадом визуелних и термалних слика користећи алгоритме дубоког учења са надгледањем. Скалабиност представљеног решења и аутоматизација путем вештачке интелигенције је од велике предности.

Помоћу савремених алгоритама вештачке интелигенције за обраду слике и видеа омогућена је категоризација стања спољашњости зграда. Ова, у истраживању примењена методологија, доприноси планирању стратегија за дијагностику изолације са већом тачношћу и стабилношћу и помаже у разумевању и прецизирању захтева за методе реконструкције. На основу термалних информација са снимака процењене су површинске температуре појединачних елемената и реализовано је опсежно утврђивање стања топлотне отпорности објеката и предвиђена је изолациона способност зграда. Класична инфрацрвена инспекција захтева детаљне прегледе специјалиста, а методом креираном у овом пројекту омогућена је ефикасна и поуздана класификација стања фасада великог броја објеката у градској области.

Ради одржавања фасада зграда потребне су периодичне сигурносне и техничке контроле. Појединачне аномалије кроз које може протицати топлотна енергија и које често нису видљиве, овим концептом се могу благовремено и ефикасно регистровати. Инфрацрвеном инспекцијом се могу смањити трошкови преко увида у захтеве за поправке објекта што пружа могућност повољнијег грејања и хлађења. Термографија обезбеђује повољан, ефикасан и удаљен приступ и снимање широког опсега површина грађевинских објеката. Уз то, концепт се може користити за оптимизацију дизајна изолације зграда.

Аутоматизација извештаја о енергетским губицима је предуслов за постизање циљева везаних за побољшање енергетске ефикасности и здравијег окружења. Извесно је да ће у блиској будућности доћи до наглог пораста коришћења визуелних података због распрострањене примене беспилотних летелица, као и надзорних станица за одржавање грађевинских објеката. Због тога се у домену истраживања очекује даљи убрзани развој система заснованих на вештачкој интелигенцији, којима се може ефикасно управљати великом количином различитих података.

## Референце

- [1] P. K. S. Rathore, S. K. Shukla, “An experimental evaluation of thermal behavior of the building envelope using macroencapsulated PCM for energy savings”, *Renewable Energy*, vol. 149, pp. 1300-1313, 2020.
- [2] G. V. Kaliyannan, R. Rathanasamy, R. Gunasekaran, M. S. Anbupalani, M. Chinnasamy, S. K. Palaniappan, “Doping of Carbon Nanostructures for Energy Application”, *Defect Engineering of Carbon Nanostructures*, pp. 83- 109, 2022.
- [3] D. D’Agostino, B. Cuniberti, P. Bertoldi, “Energy consumption and efficiency technology measures in European non-residential buildings”, *Energy and Buildings*, Vol. 153, pp. 72-86, 2017.
- [4] K. Chen, *Analysis and Management of UAV-Captured Images towards Automation of Building Façade Inspections*, Doctoral Thesis, Virginia Polytechnic Institute and State University, 2020.
- [5] M. De Filippo, S. Asadiabadi, J. S. Kuang, D. K. Mishra, H. Sun, “AI- powered inspections of facades in reinforced concrete buildings”, *HKIE Transactions*, 2020.
- [6] Z. Mayer, A. Epperlein, R. Volk, E. Vollmer, F. Shuilmann, *Comparison of building thermography approaches using terrestrial and aerial thermographic images*, IOP Conference Series: Earth and Environmental Science, Berlin, 2022.
- [7] T. -Z Xiang, G. -S. Xia, L. Zhang, “Mini-Unmanned Aerial Vehicle-Based Remote Sensing: Techniques, applications and prospects “, *IEEE Geoscience and Remote Sensing Magazine*, vol. 7, no. 3, pp. 29-63, 2019.
- [8] A. Benz, J. Taraben, P. Debus, B. Habte, L. Oppermann, N. Hallermann, C. Voelker, V. Rodehorst, G. Morgenthal, “Framework for a UAS-based assessment of energy performance of buildings”, *Energy and Buildings*, Vol. 250, 111266, 2021.
- [9] A. Israr, G. E. M. Abro, M. S. A. Khan, M. Farhan, S. A. B. M. Zulkifli, “Internet of Things (IoT) Enabled Unmanned Aerial Vehicles for the Inspection of Construction Sites: A Vision and Future Directions”, *Mathematical Problems in Engineering*, Vol 2021, pp. 1 -15, 2021.
- [10] C. Daffara, R. Muradore, N. Piccinelli, N. Gaburro, T. de Rubeis, D. Ambrosini, “A Cost-Effective System for Aerial 3D Thermography of Buildings”, *Journal of Imaging*, 6, 76, 2020.
- [11] M. Previtali, L. Barazzetti, R. Brumana, F. Roncoroni, “Thermographic analysis from UAV platforms for energy efficiency retrofit applications”, *Journal of Mobile Multimedia 9(1): 66-82*, 2013.
- [12] U. Avdan, O. Kaplan, G. Kaplan, “Determination of building materials with IR Thermography in historical buildings”, *International Journal of Engineering and Geosciences*, 2018.



- [13] S. Oh, S. Ham, S. Lee, “Drone-Assisted Image Processing Scheme using Frame-Based Location Identification for Crack and Energy Loss Detection in Building Envelopes”, *Energies*, 14(19), 6359, 2021.
- [14] I. S. Dias, I. Flores-Colen, A. Silva, “Critical Analysis about Emerging Technologies for Building’s Facade Inspection”, *Buildings*, 11(2), 53, 2021.
- [15] I. Garrido, M. Solla, S. Lagüela, M. Rasol, “Review of InfraRed Thermography and Grund-Penetrating Radar Applications for Building Assessment”, *Advances in Civil Engineering*, 2022.
- [16] C. R. Linan, M. J. M. Conde, P. R. de Hita, F. P. Galvez, “Application of Non-Destructive Techniques in the Inspection of Wooden Structures of Protected Buildings: The Case of Nuestra Senora de los Dolores Church (Isla Cristina, Huelva)”, *International Journal of Architectural Heritage*, 2014.
- [17] Y. Himeur, K. Ghanem, A. Alsalemi, F. Bensaali, A. Amira, “Artificial intelligence based anomaly detection of energy consumption in buildings: A review, current trends and new perspectives”, *Applied Energy*, 2021.
- [18] Z. Fang, W. Wang, *Analysis and optimization of temperature measurement distance on the infrared temperature measurement accuracy of building envelope*, 2<sup>nd</sup> International Conference on Energy Utilization and Automation (ICEUA), Sanya, 2023.
- [19] K. Sharma, “Analysis of Non-destructive Testing for Improved Inspection and Maintenance Strategies”, *The e-Journal of Nondestructive Testing*, 2023.
- [20] Y. Yingying, T. V. Wu, A. Sempey, J. Dumoulin, J.-C. Batsale, “Short time non-destructive evaluation of thermal performances of building walls by studying transient heat transfer”, *Energy and Buildings*, Vol. 184, pp. 141-151, 2018.
- [21] A. Ficapal, I. Mutis, “Framework for the Detection, Diagnosis, and Evaluation of Thermal Bridges Using Infrared Thermography and Unmanned Aerial Vehicles”, *Buildings*, 9(8), 179, 2019.
- [22] H. Li, G. Feng, Y. Pu, H. Wang, *Case analysis of thermal defect detection of near-zero energy building envelope based on infrared thermography*, 16<sup>th</sup> ROOMVENT Conference, Xi’an, 2022.
- [23] A. Adan, V. Perez, A. Ramon, F. J. Castilla, “Correction of Temperature from Infrared Cameras for More Precise As-Is 3D Thermal Models of Buildings”, *Applied Sciences*, 13(11), 6779, 2023.
- [24] A. Al-Habaibeh, A. Sen, J.C. Chilton, “Evaluation Tool For The Thermal Performance of Retrofitted Buildings Using An Integrated Approach of Deep Learning Artificial Neural Networks and Infrared Thermography”, *Energy and Built Environment*, Vol. 2, pp. 345-365, 2020.
- [25] Z. Wei, A. Osman, B. Valeske, X. Maldague, “Pulsed Thermography Dataset for Training Deep Learning Models”, *Applied Sciences*, 13(5), 2901, 2023.

- [26] K. Stokowiec, S. Sobura, “Hand-held and UAV camera comparison in building thermal inspection process”, *Journal of Physics Conference Series*, 2022.
- [27] M. Fox, D. Coley, S. Goodhew, P. de Wilde, “Thermography methodologies for detecting energy related building defects”, *Renewable and Sustainable Energy Reviews*, Vol 40, pp. 296-310, 2014.
- [28] R. Usamentiaga, P. Venegas, J. Guerediaga, L. Vega, J. Molleda, F. G. Bulnes, “Infrared Thermography for Temperature Measurement and Non-Destructive Testing”, *Sensors*, 14, 12305-12348, 2014.
- [29] T. – Y. Lin, P. Dollar, R. Girshick, K. He, B. Hariharan, S. Belongie, “Feature Pyramid Networks for Object Detection“, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 2117-2125, 2017.
- [30] T.-Y. Lin, P. Goyal, R. Girshick, K. He, P. Dollar, “Focal Loss for Dense Object Detection“, *IEEE International Conference on Computer Vision (ICCV)*, Venice, 2017.
- [31] L. Ali, F. Alnajjar, H. A. Jassmi, M. Gocho, W. Khan, M. A. Serhani, “Performance Evaluation of Deep CNN-Based Crack Detection and Localization Techniques for Concrete Structures”, *Sensors*, 21(5), 2021.
- [32] M. D. Filippo, S. Asadiabadi, J. S. Kuang, D. K. Mishra, H. Sun, “AI-powered inspections of facades in reinforced concrete buildings”, *HKIE Transactions*, 2023.
- [33] R. Szeliski, “*Computer Vision: Algorithms and Applications*”, Springer Nature: Berlin/ Heidelberg, Germany, 2010.
- [34] A. Geron, “*Hands-on Machine Learning with Scikit-Learn, Keras & TensorFlow*”, O’Reilly, Second Edition, 2019.
- [35] J. Krohn, G. Beyleveld, A. Bassens, “*Deep learning illustriert*”, dpunkt.verlag GmbH, 2020.
- [36] S. Harbuck, D. Harbuck, “*Residential Energy Auditing and Improvement*”, The Fairmont Press: Lilburn, GA, USA, 2014.
- [37] J. A. Duffie, W. A. Beckman, N. Blair, “*Solar Engineering of Thermal Processes, Photovoltaics and Wind*”, 5th ed., John Wiley & Sons: Hoboken, NJ, USA, 2020.
- [38] R. Jain, R. Kasturi, B. G. Schunsk, “*Machine Vision Book*”, McGraw-Hill, 1995.
- [39] M. Leggiero, B. Andrew, R. Elliott, J. Indergaard, J.B. Sharma, T. Vogel, “Radiative heat loss estimation of building envelopes based on 3D thermographic models utilizing small unmanned aerial systems”, *Energy Buildings*, 2021., 244, 110957.
- [40] P. A. Fokaides, S. A. Kalogirou, “Application of infrared thermography for the determination of the overall heat transfer coefficient (U-Value) in building envelopes”, *Applied Energy*, 2011.

- [41] A. Mayer, A. W. Stolos, T. Sasin, J. Krawczyk, “Infrared building inspection with unmanned aerial vehicles”, *Transactions of the Institute of Aviation*, 2015.
- [42] D. Liu, X. Xia, J. Chen, S. Li, “Integrating Building Information Model Augmented Reality for Drone-Based Building Inspection”, *Journal of Computing in Civil Engineering*, 2021.
- [43] Z. Mayer, J. Kahn, Y. Hou, M. Götz, R. Volk, F. Schultmann, “Deep learning approaches to building rooftop thermal bridge detection from aerial images”, *Elsevier*, 2023.
- [44] Y. Himeur, M. A. Elnour, F. Fadli, N. Meskin, I. Petri, Y. Rezgui, F. Bensaali, A. Amira, “AI-big data analytics for building automation and management systems: a survey, actual challenges and future perspectives”, *Artificial Intelligence Review*, 2022.
- [45] I. Paduano, A. Mileto, E. Lofrano, “A Perspective on AI-Based Image Analysis and Utilization Technologies in Building Engineering: Recent Developments and New Directions”, *Buildings*, 2023.
- [46] A. G. Entrop, A. Vasenev, “Infrared drones in the construction industry: designing a protocol for building thermography procedures”, *Energy Procedia*, 2017.
- [47] H. Zheng, X. Zhong, J. Yan, L. Zhao, “A Thermal Performance Detection Method for Building Envelope Based on 3D Model Generated by UAV Thermal Emagery”, *Energies*, 2020.
- [48] M. Previtali, L. Barazzeti, R. Brumana, F. Roncoroni, “Thermographic analysis from UAV platforms for energy efficiency retrofit applications”, *Journal of Mobile Multimedia*, 2013.
- [49] T. X. B. Nguyen, K. Rosser, J. Chahl, “A Review of Modern Thermal Imaging Sensor Technology and Applications for Autonomous Aerial Navigation”, *Journal of Imaging*, 2021.
- [50] S. Jordan, J. Moore, S. Hovet, J. Box, K. Kirsche, J. Perry, D. Lewis, Z. Tse, “State of the Art Technologies for UAV Inspections”, *IET Radar, Sonar & Navigations*, 2017.
- [51] V. Pablo, E. Ivorra, M. O. Perez, I. S. de Ocariz, “Towards the Automation of Infrared Thermography Inspections for Industrial Maintenance Applications”, *Sensors*, 2022.
- [52] A. Preda, I. C. Scurtu, “Thermal image building inspection for heat loss diagnosis”, *Journal of Physics Conference Series*, 2019.
- [53] C Eschmann, C.-M. Kuo, C. H. Kuo, C. Boller, “Unmanned Aircraft Systems for Remote Building Inspection and Monitoring”, *6th European Workshop on Structural Health Monitoring*, 2012.
- [54] J.-C. Candore, J. I. Bodnar, A. Szefflinski, L. t Ibos, S. Datcu, Y. Candau, S. Mattei, J.-C. Frichet, “Helps with the thermal diagnosis of the building: Detection of

defects of insulation by stimulated infra-red thermography”, QIRT, Krakow, Poland, 2008.

[55] C. Wang, *Non-Invasive 3D Thermal Modeling for Buildings*, *International Conference on Sustainable Design and Construction*, Fort Wort, USA, 2012.

[56] R. Plesu, G. Teodoriu, G. Taranu, “Infrared Thermography Applications for Building Investigation”, *The Bulletin of the Polytechnic Institute of Jassy, Construction. Architecture Section*, 2012., 58, 157 - 168

[57] B. Barahona, R. Buck, O. Okaya, P. Schuetz, “Detection of thermal anomalies on building facades using infrared thermography and supervised learning”, *Journal of Physics Conference Series*, 2021.

[58] F. Asdrubali, G. Baldinelli, F. Bianchi, A. L. Pisello, “Infrared Thermography Assessment of Thermal Bridges in Building Envelope: Experimental Validation in a Test Room Setup”, *Sustainability*, 2014.

[59] J. R. Martinez-de Dios, A. Ollero, *Automatic Detection of Windows Thermal Heat Losses in Buildings Using UAVs*, World Automation Congress, Budapest, Hungary, 2006.

[60] E. Barreira, R. M. S. F. Almeda, M. L. Simoes, “Emissivity of Building Materials for Infrared Measurements”, *Sensors*, 21, 196, 12021.

[61] D. Sadhukhan, S. Peri, N. Sugunaraj, A. Biswas, D. F. Selvaraj, K. Koiner, A. Rosener, M. Dunlevy, N. Goveas, D. Flynn, P. Ranganathan, “Estimating Surface temperature from thermal imagery of buildings for accurate thermal transmittance (U-value): A machine learning perspective”, *Journal of Building Engineering, Elsevier*, 2020.

[62] W. Minkina, D. Klecha, “Atmospheric transmission coefficient modelling in the infrared for thermovision measurements”, *Journal of Sensors and Sensor Systems*, 2016.

[63] A. Weglarz, “Using Artificial Intelligence in energy efficient construction”, *E3S Web Conferences*, 2018.

[64] Q. Fang, B. D. Nguyen, C. I. Castanedo, Y. Duan, X. Maldague, “Automatic defect detection in infrared thermography by deep learning algorithm”, *Defense and Commercial Sensing*, 2020.

[65] G. K. Balakrishnan, C. T. Yaw, S. P. Koh, T. Abedin, “A Review of Infrared Thermography for Condition-Based Monitoring in Electrical Energy: Applications and Recommendations”, *Energies*, 2022.

[66] G. K. Balakrishnan, C. T. Yaw, S. P. Koh, T. Abedin, “A Review of Infrared Thermography for Condition-Based Monitoring in electrical Energy: Applications and Recommendations”, *Energies*, 2022.

[67] H. Rezatofighi, N. Tsoi, J. Y. Gwak, A. Sadeghian, I. Reid, S. Savarese, *Generalized Interseccion over Union: A Metric and A Loss for Building Box*

*Regression*, IEEE/CVF Conference on computer Vision and Pattern Recognition, 2019.

[68] M. Tanasković, L. Fagiano, R. Smith, P. J. Goulart, M. Morari, *Adaptive model predictive control for constrained linear systems*, Control Conference, 2013.

[69] M. S. Stanković, M. Beko, S. S. Stanković, “Distributed Value Function Approximation for Collaborative Multi-Agent Reinforcement Learning”, *IEEE Transactions on control of Network Systems*, 22, 2562, 2021.

[70] Y. Arjoune, S. Peri, N. Sugunraj, A. Biswas, “An Instance Segmentation and Clustering Model for Energy Audit Assessments in Built Environments: A Multi-Stage Approach”, *Sensors*, 2021.

[71] M. Tanasković, D. Sturzenegger, R. Smith, M. Morari, “Robust Adaptive Model Predictive Building Climate Control”, IFAC, 2017.

[72] A. Maxwell, T. A Warner, L. A. Guillen, “Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies Part 1: Literature Review”, *Remote Sensing*, 2021.

[73] Window detection in street scenes,  
<https://www.kaggle.com/datasets/rude009/window-detection-in-street-scenes>

[74] J. Gomez, A. Tascon, “A protocol for using unmanned aerial vehicles to inspect agro-industrial buildings”, *Informes de la Construcción*, 2021.

[75] M. Videras, S. G. Melgar, A. S. Cordero, J. M. A. Marquez, “A Critical Review of Unmanned Aerial Vehicles (UAVs) Use in Architecture and Urbanism: Scientometric and Bibliometric Analysis”, *Applied Sciences*, 2021.

[76] A. Sledz, J. Unger, C. Heipke, “UAV-based thermal anomaly detection for distributed heating networks”, *The international Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences*, 2020.

[77] M. Ortega, E. Ivorra, A. Juan, P. Venegas, J. Martinez, M. Alcaniz, “MANTRA: An effective System Based on Augmented Reality and Infrared Thermography for Industrial Maintenance”, *Appl. Sci.*, 2021, 11, 385

[78] O. Fudym, H. R B Orlande, M. Bamford, J.-C. Batsale, “Bayesian approach for thermal diffusivity mapping from infrared images with spatially random heat pulse heating”, *Journal of Physics*, 2008.

[79] M. M. Resende, E. B. Gambare, L. A. Silva, Y. de S. Cordeiro, E. Almeida, R. P. Salvador, “Infrared thermal imaging to inspect pathologies on facades of historical buildings: A case study on the Municipal Market of Sao Paulo, Brazil”, *Case Studies in Construction Materials*, 2022.

[80] V. Vavilov, “Thermal non destructive testing: short history and state-of-art”, *Quantitative InfraRed Thermography*, 1992.

[81] C. Ibarra-Castanedo, J. R. Tarpani, X. P. V. Maldague, “Nondestructive testing with thermography”, *European Journal of Physics*, 2013.

- [82] P. Fokaides, S. Kalogirou, “Application of infrared thermography for the determination of the overall heat transfer coefficient (U-Value) in building envelopes”, *Applied Energy* 88(12): 4358-4365, 2011.
- [83] W. Minkina, D. Klecha, “Atmospheric transmission coefficient modelling in the infrared for thermovision measurements”, *Journal of Sensors and Sensor Systems*, 5(1), 2016.
- [84] V. Chinnasamy, S. K. Palaniappan, M. K. A. Raj, M. Rajendran, H. Cho, “Thermal Energy Storage and Its Applications”, *Materials for Solar Energy Conversation*, 2021., 353-377.
- [85] G. Ali, X. Qian, M. Syung, W. Andy, Z. Hui, H. Yingdong, M. Alexander, L. Ronnen, “Infrared-Fused Vision-Based Thermoregulation Performance Estimation for Personal Thermal Comfort-Driven HVAC System Controls”, *Buildings*, 12(8), 1241., 2022
- [86] M. Kent, N. K. Huynh, S. Schiavon, S. Selkowitz, “Using support vector machine to desk illuminance sensor blockage for closed-loop daylight harvesting”, *Energy and Buildings*, 2022.
- [87] C.-C. Cheng, D. Lee, “Smart Sensors enable Smart Air Conditioning Control”, *Sensors*, 11179- 11203, 2014.
- [88] G. Batchuluun, J. K. Kang, D. T. Nguyen, T. D. Pham, M. Arsalan, K. R. Park, “Deep Learning-Based Thermal Image Reconstruction and Object Detection”, *IEEE Access*, PP(99):1-1, 2020.
- [89] N. Yadav, TVA-GAN: “Attention Guided Generative Adversarial Network For Thermal To Visible Image Transformations”, 2021., <https://api.semanticscholar.org/CorpusID:234865000>
- [90] V. Mizginov, V. Kniaz, N. Fomin, “A method for synthesizing thermal images using GAN multi-layered approach”, *The International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences*, 2021.
- [91] I. B. Akkaya, F. Altinel, U. Halici, *Self-training Guided Adversarial Domain Adaptation For Thermal Imagery*, IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2021.
- [92] G. Baasch, G. Rousseau, R. Evins, “A Conditional Generative Adversarial for Energy Use in Multiple Buildings Using Scarce Data”, *Energy and AI*, 5(5):100087, 2021.
- [93] D. Wan, X. Zhao, W. Lu, P. Li, X. Shi, H. Fukuda, “A Deep Learning Approach toward Energy-Effective Residential Building Floor Plan Generation”, *Sustainability*, 14(13), 8074, 2022.
- [94] Y. Hou, M. Chen, R. Volk, L. Soibelman, “An Approach to Semantically Segmenting Building Components and Outdoor Scenes Based on Multichannel Aerial Imagery Datasets”, *Remote Sens*, 2021., 13(21), 4357

- [95] A. Funmilola A, Oke O.A., Adedeji T.O., Alade O.M., Adewusi E.A, “Fuzzy k-c-means Clustering Algorithm for Medical Image Segmentation”, *Journal of Information Engineering and Applications*, 2012.
- [96] K. Kashiwabara, K. Kazama, Y. Marumo, “Performance Evaluation of Image Registration for Map Images”, *Journal of Robotics and Mechatronics*, 2023.
- [97] D. Gertsvolf, M. Horvat, A. Khademi, D. Aslam, U. Berardi, “Image Processing for Future Machine Learning Algorithm Applications on Infrared Thermography of Building Envelope Systems”, *Proceedings of the 5th International Conference on Building Energy and Environment, Environmental Science and Engineering*, 2023.
- [98] X. Maldague, “Applications of Infrared Thermography in Nondestructive Evaluation”, *Trends in optical nondestructive testing*, 2000.
- [99] A. Shibani, A. Agha, K. Ambiti, D. Hassan, “Drone Application for Visual Inspection and Surveying: The case of High-Rise Residential Building in India”, *International Journal for Research in engineering Application & Management*, Vol 08, Issue 11, 2023.
- [100] H. Liang, S.-C. Lee, W. Bae, J. Kim, S. Seo, “Towards UAVs in Construction: Advancements, Challenges, and Future Directions for Monitoring and Inspection”, *Drones*, 2023.
- [101] A. Francois, L. Ibos, V. Feuillet, J. Meulemans, “Building thermal bridge heat losses quantification by infrared thermography. Steady-state evaluation and uncertainty calculation”, *Journal of Physics*, 2019.
- [102] M. H. A. L. Youcef, V. Feuillet, L. Ibos, Y. Candau, P. Balcon, A. Filloux, *In situ quantitative diagnosis of insulated building walls using passive infrared thermography*, 11th International Conference on Quantitative InfraRed Thermography, 2012.
- [103] Y. He, B. Deng, H. Wang, L. Cheng, K. Zhou, S. Cai, F. Ciampa, “Infrared machine vision and infrared thermography with deep learning: a review”, *Infrared Physics & Technology*, 2021.
- [104] L. Liu, R.-J. Yan, V. Maruvanchery, E. Kayacan, I.-M. Chen, L. K. Tiong, “Transfer learning on convolutional activation feature as applied to a building quality assessment robot”, *International Journal of Advanced Robotic Systems*, 2017.
- [105] A. Busheska, N.Almeida, N. Sabella, E. de A. Rocha, “Machine Learning and Thermography Applied to the Detection and Classification of Cracks in Building”, DOI: 10.48550/arXiv.2212.14730, 2022.
- [106] I. Nardi, E. Lucchi, T. de Rubeis, D. Ambrosini, “Quantification of heat energy losses through the building envelope: a state-of-the-art analysis with critical and comprehensive review on infrared thermography”, *Building and Environment*, 2018.
- [107] F. Elghaish, S. T. Matarneh, S. Talebi, S. Abu-Samra, “Deep learning for detecting distresses in buildings and pavements: A critical gap analysis”, *Construction Innovation ahead-of-print*, 2021.

- [108] C. H. Wong, M. H. Abdul Samad, N. Taib., *Potential and limitation of AI system in building services and control management system*, The 5th International Conference on rebuilding Place, 2021.
- [109] M. De Filippo, S. Asadiabadi, N. Ko, H. Sun, “Concept of Computer Vision Based Algorithm for Detection Thermal Anomalies in Reinforced Concrete Structures”, *Proceedings*, 2019., 7, 18
- [110] E. Rosina, E. C. Robison, “The Application of Infrared Thermography on Wood-Framed North American Historic Buildings”, *APT Bulletin*, 2002.
- [111] Z. Li, Y. Jin, X. Liang, J. Zeng, “Thermography evaluation of defect characteristics of building envelopes in urban villages in Guangzhou, China”, *Case Studies in Construction and Materials*, 2022.
- [112] A. Bagheri, K. N. Genikomsakis, S. Koutra, V.s Sakellariou, C. S. Iokimidis, “Use f AI Algorithms in Different Building Topologies for Energy Efficiency towards Smart Buildings”, *Buildings*, 2021.
- [113] T. Xu, *Generative Adversarial Networks for Sequential Learning*, *Doctoral thesis*, London School of economics and Political Sciences, 2022.
- [114] T. Poos, E. Varju, “Mass transfer coefficient for water evaporation by theoretical and empirical correlations”, *Elsevier*, Vol. 153, 2020.
- [115] H. Kayan, R. Eslampanah, F. Yeganli, M. Askar, *Heat leakage detection and surveillance using aerial thermography drone*, 26<sup>th</sup> Signal Processing and Communications Applications Conference, 2018.
- [116] S. V. D. Vijver, M. Steeman, K. Carbonez, N. V. D. Bossche, “On the use of infrared thermography to assess air infiltration in building envelopes”, *International workshop: Quality of Methods for Measuring Ventilation and Air Infiltration in Buildings*, 2014.
- [117] M. V. Rodriguez, S. G. Melgar, A. S. Cordero, J. M. A. “Marquez, A Critical Review of Unmanned Aerial Vihicles (UAVs) Use in Architecture and Urbanism: Scientometric and Bibliometric Analysis“, *Applied Sciences*, 2021.
- [118] Keras Retina Net, <https://github.com/fizyr/keras-retinanet>
- [119] IR Survey. 2022. Available online: <https://github.com/milulitech/irsurvey>
- [120] K. Wang, M. Z. Liu, “Object Recognition at Night Scene Based on DCGAN and Faster-RCNN”, *IEEE Access*, 2020.
- [121] L.-C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, A. L. Yuille, “DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 40, 2018.
- [122] Y. Zhang, J. Wang, X. Yang, “Real-time vehicle detection and tracking in video based on faster R-CNN”, *Journal of Physics Conference Series*, 2017.



- [123] Y. Song, C. Ma, X. Wu, L. Gong, L. Bao, W. Zuo, C. Shen, R. Lau, M.-H. Yang, *VITAL: Visual Tracking via Adversarial Learning*, IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018.
- [124] I. Walter, M. Tanasković, M. Stanković, “Energy Efficiency Assessment for Buildings Based on the Generative Adversarial Network Structure”, *Eng*, 4, 2178-2190, 2023.
- [125] L. Tian, Z. Wang, W. Liu, C. Yuhua, A. Fuad, L. Xiaohui, “A New GAN-Based Approach to Data Augmentation and Image Segmentation for Crack Detection in Thermal imaging Tests”, *Cognitive Computation*, 13, 1263-1273.
- [126] M. R. Solomon, “*Consumer Behavior: Bying, Having and Being*”, Pearson, 2017.
- [127] S. Ren, K. He, R. Girshick, J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks”, *NIPS*, 2016.
- [128] A. Nazib, C. Oh, C.-W. Lee, *Object Detection and Tracking in Night Time Video Surveillance*, 10<sup>th</sup> International Conference on Ubiquitous Robot and Ambient Intelligence, Island, 2013.
- [129] Y. Xiao, A. Jiang, J. Ye, W. Mingwen, “Making of Night Vision: Object Detection Under Low-Illumination”, *IEEE Access*, 2020.
- [130] M. E Rane, U. Dias, “Motion Based Object Detection And Classification For Night Surveillance”, *ICTACT Journal on Image and Video Processing*, 2012.
- [131] L. Fu, H. Yu, F. Juefei-Xu, J. Li, Q. Guo, S. Wang, “Let There be Light: Improved Traffic Surveillance via Detail Preserving Night-to-Day Transfer”, *IEEE Transactions on Circuits and Systems for Video Technology*, 2022.
- [132] L. Wang, K. Huang, Y. Huang, T. Tan, *Object detection and tracking for night surveillance based on salient contrast analysis*, 16<sup>th</sup> IEEE International Conference on Image Processing, 2009.
- [133] S. Pellegrini, A. Ess, M. Tanasković, L. V. Gool, *Wrong turn – No dead end: A stochastic pedestrian motion model*, IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, 2010.
- [134] A. Bhandari, A. Kafle, P. Dhakal, D. B. Kshatri, P. R. Joshi, “Image Enhancement and Object Recognition for Night Vision Surveillance”, arXiv preprint arXiv:2006.05787, 2018.
- [135] C. Li, W. Xia, Y. Yan, L. Bin, J. Tang, “Segmenting Objects in Day and Night: Edge-Conditioned CNN for Thermal Image Semantic Segmentation”, *IEEE Transactions on Neural Networks and Learning Systems*, 2020.
- [136] N. Vlahović, N. Ilić, M. S. Stanković, „Deep Learning in Video Stabilization Homography Estimation“, *14th Symposium on Neural Networks and Applications*, 2018.

- [137] S. C. Hespeler, H. Nemati, E. Dehghan-Niri, “Non-destructive thermal imaging for object detection via advanced deep learning for robotic inspection and harvesting of chili peppers”, *Artificial Intelligence in Agriculture*, 2021.
- [138] L.-C. Chen, G. Papandreou, F. Schroff, H. Adam, R. “Atrous Convolution for Semantic Image Segmentation”, ArXiv abs/1706.05587, 2017.
- [139] Pixellib’s Official Documentation, <https://pixellib.readthedocs.io>
- [140] T. Poos, E. Varju, “Mass transfer coefficient for water evaporation by theoretical and empirical correlations”, *International Journal of Heat and Mass Transfer*, 2020.
- [141] I. Walter, *Modelled neural networks for multiple object tracking*, International Scientific conference on information technology and related research SINTEZA, Belgrade, Serbia, 2021.
- [142] I. Walter, M. Tanasković, *Object recognition in the dark with image segmentation*, *International Scientific Conference ETIKUM*, Novi Sad, Serbia, 2021.
- [143] I. Walter, M. Tanasković, *Pedestrian recognition in low illumination with deep neural network and SVM*, Proceedings of ARSSS International Conference, Zürich, Switzerland, 2021.
- [144] I. Walter, M. Tanasković, *Image segmentation processing for thermographic analysis*, International scientific conference on information technology and data related research Sinteza, 2022.
- [145] I. Walter, M. Tanasković, M. Stanković, „IR Building Analysis with Extraction of Elements Using Image Segmentation and RetinaNet“, *Buildings*, 2022.
- [146] [https://docs.opencv.org/3.4/de/da9/tutorial\\_template\\_matching.html](https://docs.opencv.org/3.4/de/da9/tutorial_template_matching.html)