



Kauno technologijos universitetas

Informatikos fakultetas

Statinių energinio naudingumo vertinimas taikant dirbtinio intelektu metodus termofotogrametriniams modeliams

Baigiamasis magistro studijų projektas

Justas Kardoka

Projekto autorius

prof. Agnė Paulauskaitė-Tarasevičienė

Vadovė

Kaunas, 2024



Kauno technologijos universitetas

Informatikos fakultetas

Statinių energinio naudingumo vertinimas taikant dirbtinio intelekto metodus termofotogrametriniams modeliams

Baigiamasis magistro studijų projektas

Dirbtinio intelekto informatika (6211BX007)

Justas Kardoka

Projekto autorius

prof. Agnė Paulauskaitė-Tarasevičienė

Vadovė

doc. Dalia Čalnerytė

Recenzentė

Kaunas, 2024



Kauno technologijos universitetas

Informatikos fakultetas

Justas Kardoka

Statinių energinio naudingumo vertinimas taikant dirbtinio intelekto metodus termofotogrametriniams modeliams

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Justas Kardoka

Patvirtinta elektroniniu būdu

Kardoka Justas. Statinių energinio naudingumo vertinimas taikant dirbtinio intelekto metodus termofotogrametriniams modeliams. Magistro krypties studijų baigiamasis projektas / vadovė prof. Agnė Paulauskaitė-Tarasevičienė; Kauno technologijos universitetas, Informatikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Informatikos mokslai, Informatika (B01).

Reikšminiai žodžiai: dirbtinis intelektas, pastatų šilumos nuostolių vertinimas, taškų masyvų segmentavimas, termografinės nuotraukos.

Kaunas, 2024. 57 p.

Santrauka

Pastatai išskiria 36 % visų šiltnamio efektą sukeliančių dujų. Siekiant sumažinti pastatų CO₂ pėdsaką, svarbu gebėti įvertinti pastatų šilumos nuostolius kuo efektyviau. Nors termografinės nuotraukos šiame kontekste yra labiausiai naudojamos šalčio ar šilumos tiltų aptikimui, jos gali būti panaudojamos kuriant trimates pastatų reprezentacijas. Darbe aprašyta metodologija suteikia galimybę panaudoti termofotogrametrinius modelius pastatų šilumos nuostolių skaičiavimams atlikti. Darbui sukurtas duomenų rinkinys, kuris sudarytas iš dviejų skirtingų fiksavimų to paties pastato naudojant *DJI Mavic 2 Enterprise* droną kovo mėn. ir rugpjūčio mėn. Duomenų rinkinys susideda iš 654 termonuotraukų, o iš jų termofotogrametriniai modeliai paversti į taškų masyvus turi apytiksliai 12 000 000 taškų. Paviršiaus temperatūros informacija gauta iš termonuotraukų, priskyrus atitinkamas RGB reikšmes kiekvienai paviršiaus temperatūros reikšmei. Konvertavus šiuos modelius į taškų masyvus, galima taikyti įvairius mašininio mokymo algoritmus, skirtus taškų masyvų segmentavimui atlikti. Išanalizavus tris skirtingus pastatų segmentavimo algoritmus, buvo nustatyta, kad *KPConv* algoritmas pasiekė geriausius rezultatus. Segmentavimo rezultatams buvo papildomai pritaikytas triukšmo šalinimas naudojant statistinį triukšmo aptikimą. Segmentuoti taškų masyvai buvo paversti į tinklainę ir kiekvienam tinklainės trikampio paviršiaus plotui pagal RGB reikšmę buvo priskirta atitinkama paviršiaus temperatūros reikšmė. Šilumos nuostolių skaičiavimams įvertinti buvo panaudoti duomenys iš simuliacijos, kuri buvo atlikta remiantis pastato geometrinėmis ir naudojamų medžiagų savybėmis. Šilumos nuostolių skaičiavimų rezultatai buvo tikslesni ne šildymo sezono metu, o šildymo sezono metu buvo prognozuojami didesni šilumos nuostoliai nei buvo iš tiesų. Buvo fiksuojama vidutiniška -11 kW šilumos nuostolių paklaida, užfiksuota kovo mėn. ir 0,3 kW paklaida, užfiksuota rugpjūčio mėn. Taikant darbe aprašytą metodologiją galima atlikti šilumos nuostolių skaičiavimus naudojant giliuoju mokymu grįstus algoritmus ir termofotogrametriją. Rezultatai yra tikslesni ne šildymo sezono metu, tačiau šildymo sezono metu galima identifikuoti kada yra šilumos nuostolių. Aprašyta metodologija gali būti naudinga suinteresuotoms šalims dėl pastato išskiriamo CO₂ pėdsako klausimų, taip pat galima atlikti eksperimentus ją taikant platesniu, pvz. rajono ar miesto lygmeniu. Tai yra itin aktualu šiuo metu, kuomet kova prieš klimato kaitą yra svarbi ir dažnai pabrėžiama Jungtinių Tautų darnaus vystymosi tiksluose ir Europos žaliajame kurse. Tolimesniuose darbuose būtų galima sukurti tikslesnį pastatų segmentavimo modelį, kuris būtų apmokytas naudojant termografinius taškų masyvus. Taip pat, būtų galima segmentuoti skirtingus pastato fasado elementus, pvz. langus, stogus ir pan. ir jiems taikyti skirtingus šilumos laidumo koeficientus ir emisyvumo konstantas. Taip būtų fiksuojamos tikslesnės paviršiaus temperatūros reikšmės.

Kardoka, Justas . Evaluation of Building Energy Efficiency Using Artificial Intelligence Methods for Thermophotogrammetry Models. Master's Final Degree Project / supervisor prof., Agnė Paulauskaitė-Tarasevičienė; Faculty of Informatics, Kaunas University of Technology.

Study field and area (study field group): Computer science, Informatics (B01).

Keywords: artificial intelligence, building thermal heat loss evaluation, point-cloud segmentation, thermographic images.

Kaunas, 2024. 57 p.

Summary

Buildings account for about 36 % of all greenhouse gas emissions. To lower the CO₂ emissions of buildings it is important to be able to evaluate the thermal losses of buildings as efficiently as possible. Although thermal images are used in this context for detecting cold or hot bridges, they can also be utilized for creating three-dimensional representations of buildings. In the methodology of this work, an approach for using such thermophotogrammetry models for building heat loss evaluation is studied. A dataset for this task was created, consisting of two different captures using a *DJI Mavic 2 Enterprise* drone: one in March, and one in August. The dataset consists of in total 654 thermal images, and the thermophotogrammetry models that are generated from these thermal images consist of about 12 000 000 points. Surface temperature values were extracted from thermal images by assigning a *RGB* value to each surface temperature value. After converting the thermophotogrammetry model to a thermal point-cloud, machine learning algorithms for point-cloud segmentation can be used. After analyzing three different building segmentation algorithms it was determined that *KPConv* provided the best results. The segmentation results were further refined by statistical outlier detection, which slightly improved their accuracy. Segmented point-clouds were converted to a mesh and each mesh triangle was assigned a surface temperature value to its' surface area based on RGB values. For evaluating the heat loss calculations, results from a white-box simulation were used, in which the heat losses of the building were evaluated using geometry and material properties. Heat loss evaluation results were more accurate for the non-heating season. The predicted heat loss for the heating season is higher than the actual heat losses. The average error for heat loss calculations was -11 kW for the heating season and 0,3 kW for the non-heating season. When applying the methodology described in this work it is possible to perform heat loss evaluations by using deep learning-based methods and thermophotogrammetry. The results are more accurate during the non-heating season, but during the heating season it is still possible to identify that there are heat losses occurring. The methodology can be useful for interested parties regarding the CO₂ footprint of buildings, and it can be applied for more larger scale heat loss evaluations, e.g., neighborhood or city-scale. It is especially relevant nowadays when the fight against climate change is important and often reiterated via the United Nations Sustainable Development Goals and the European Green Deal. Further works could explore creating a more accurate building segmentation model that would be trained on a thermal dataset. Also, different facade elements could be segmented with the goal of applying different heat loss coefficients and emissivity parameters. This could lead to a more accurate evaluation of surface temperatures.

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Įvadas.....	10
1. Pastatų energinio naudingumo vertinimo uždavinio analizė	11
1.1. Literatūros analizė.....	11
1.2. Egzistuojančių sprendimų šilumos nuostolių skaičiavimams atlikti naudojant termografinius modelius analizė	17
2. Dirbtiniu intelektu grįstos pastatų energinio naudingumo vertinimo sistemos projektavimas	20
3. Termografinių duomenų analizė.....	26
3.1. Termografinių nuotraukų ir jų metaduomenų analizė.....	26
3.2. Termografinio taškų masyvo sudaryto iš termografinių nuotraukų analizė.....	29
3.3. Termografinio taškų masyvo segmentavimo duomenų rinkinio paruošimas.....	31
4. Pastatų segmentavimo termografiniuose taškų masyvuose ir energinio naudingumo skaičiavimo eksperimentai ir rezultatai	33
4.1. Statinių segmentavimo termografiniuose taškų masyvuose eksperimentai.....	33
4.1.1. Statinių segmentavimas taškų masyvuose naudojant RANSAC algoritimą.....	33
4.1.2. Statinių segmentavimas taškų masyvuose naudojant <i>RandLA-Net</i> modelį.....	35
4.1.3. Statinių segmentavimas taškų masyvuose naudojant <i>KPConv</i> modelį.....	36
4.1.4. Triukšmo šalinimas segmentuotuose taškų masyvuose	37
4.2. Statinių energetinio naudingumo vertinimo eksperimentai	38
5. Dirbtiniu intelektu grįstos pastatų energinio naudingumo vertinimo sistemos dokumentacija.....	43
5.1. Dirbtiniu intelektu grįstos pastatų energinio naudingumo vertinimo sistemos diegimo vadovas	43
5.2. Dirbtiniu intelektu grįstos pastatų energinio naudingumo vertinimo sistemos naudojimo vadovas.....	43
5.2.1. <i>DJIWrapper</i> klasės naudojimo vadovas.....	43
5.2.2. <i>ThermalLossEvaluation</i> klasės naudojimo vadovas.....	44
Išvados	45
Literatūros sąrašas	45

Lentelių sąrašas

1.1 lentelė. Skirtingų egzistuojančių sprendimų palyginimas	19
2.1 lentelė. Su paviršiaus temperatūra susijusių EXIF elementų iš DJI termonuotraukų metaduomenų aprašymas	25
3.1 lentelė. Darbe naudojamo duomenų rinkinio parametrai	26
3.2 lentelė. RGB reikšmės ir dekoduoja paviršiaus temperatūra keliems atsitiktinai parinktos nuotraukos taškams.....	27
3.3 lentelė. Termografinių nuotraukų duomenų rinkinio temperatūros reikšmių metrikos ...	28
4.1 lentelė. RANSAC algoritmo rezultatai naudojant $n = 3$, $niter = 1000$, $thres = 0,3$, $np = 7$	35
4.2 lentelė. <i>RandLA-Net</i> algoritmo rezultatai naudojant $bs = 4$, $lr = 0,01$, $lrdecay = 0,95$	36
4.3 lentelė. <i>KPConv</i> algoritmo rezultatai naudojant $bs = 1$, $lr = 0,01$, $lrdecay = 0,98477$...	37
4.4 lentelė. <i>KPConv</i> algoritmo rezultatai pašalinus triukšmą naudojant statistinį triukšmo šalinimą.....	38
4.5 lentelė. Atsitiktinai parinktų tinklainės trikampių plotai ir paviršiaus temperatūros	39
4.6 lentelė. Pastato šiluminės energijos naudingumo eksperimentų kovo mėn. fiksavimui rezultatai.....	39
4.7 lentelė. Pastato šiluminės energijos naudingumo eksperimentų rugpjūčio mėn. fiksavimui rezultatai.....	40
5.1 lentelė. <i>DJIWrapper</i> klasės funkcijų aprašas	43
5.2 lentelė. <i>ThermalLossEvaluation</i> klasės funkcijų aprašas	44

Paveikslų sąrašas

1.1 pav. Laguelo sugeneruotas BIM modelis, naudojantis tris skirtingas tekstūras	11
1.2 pav. Paivo originalaus (a), teisingai segmentuoto (b) ir segmentuotų pagal skirtingus algoritmus (c, d, e) taškų masyvų palyginimas	11
1.3 pav. Zango pateikti skylėtų taškų masyvų pavyzdžiai	12
1.4 pav. Rističos užfiksuotas šalčio tiltas, naudojant infraraudonųjų spindulių kamerą	12
1.5 pav. Zumro darbe naudojama termografinė nuotrauka, kurioje galima matyti pažymėtus žemos paviršiaus temperatūros taškus	13
1.6 pav. Dlesko darbe naudojamas taškų masyvas, kuriame papildomai užkoduota temperatūros informacija kiekvienam taškui	14
1.7 pav. Tarša-Kurdžio stogų segmentavimas naudojant klasikinį RANSAC algoritmą mažiau tankiam (a) ir daugiau tankiam (b) taškų masyve	15
1.8 pav. Maherio segmentuoto termografinio taškų masyvo (a) ir originalios to paties objekto nuotraukos (b) palyginimas	16
1.9 pav. Huasaso sukurto <i>RandLA-Net</i> modelio architektūra	17
1.10 pav. Landriuo sukurto sprendimo žingsniai	17
1.11 pav. <i>EnergyPlus</i> programinės įrangos suderinamumo su kita programine įranga atvaizdavimas. Šaltinis: https://www.energy.gov/eere/buildings/downloads/energyplus-0	18
1.12 pav. <i>VisionLidar</i> programinės įrangos galimybės automatiškai nustatyti žemės plokštumą taškų masyve. Šaltinis: https://www.youtube.com/watch?v=uaTwxoPpbic	18
2.1 pav. Sistemos panaudojimo atvejų diagrama	20
2.2 pav. 1 PA „Užkrauti duomenis“ veiklos diagrama	21
2.3 pav. Sistemos šilumos nuostolių skaičiavimo žingsniai	21
2.4 pav. Pastatų segmentavimo įvesties ir išvesties pavyzdys taikant darbe naudojamą duomenų rinkinį	22
2.5 pav. Termografinės tinklainės apdorojimo nustatant trikampių spalvą ir paviršiaus plotą pavyzdys	22
2.6 pav. Pastato paviršiaus temperatūrų iš termonuotraukų priskyrimo RGB reikšmėms vizualizacija	23
2.7 pav. Pastato termografinės tinklainės trikampių plotų ir temperatūrų apjungimo vizualizacija	23
2.8 pav. 4 PA „Atlikti pastatų segmentavimą taškų masyvuose“	24
2.9 pav. Sistemos duomenų klasių diagrama	24
3.1 pav. Atsitiktinai iš duomenų rinkinio parinktos termografinės nuotraukos	27
3.2 pav. Termografinių nuotraukų duomenų rinkinio temperatūros reikšmių <i>box-plot</i> grafikas	28
3.3 pav. Duomenų rinkinyje naudojamas termofotogrametrinis modelis	29
3.4 pav. Priartintas duomenų rinkinyje naudojamas termofotogrametrinis modelis	30
3.5 pav. Sprendime naudojamo PLY bylos antraštė ir pirmos taškų masyvą aprašančios eilutės	30
3.6 pav. Termofotogrametrinis modelis ir statinio paviršius reprezentuojantys <i>bounding-box</i> objektai	31
3.7 pav. <i>Bounding-box</i> elementas iš duomenų rinkinio sukurto naudojant <i>Supervisely</i>	31

4.1 pav. Du segmentuotų statinio sienų pavyzdžiai, kuriuose galima matyti tinkamai (kairėje) ir iš dalies tinkamai (dešinėje) segmentuotas statinio sienas	34
4.2 pav. Netinkamai segmentuotos statinio sienos pavyzdys, kuriame galima matyti skyles...	34
4.3 pav. <i>RandLA-Net</i> modelio segmentavimo rezultatas	35
4.4 pav. <i>KPConv</i> modelio segmentavimo rezultatas	36
4.5 pav. Segmentuotas taškų masyvas, kuriame matomas aptiktas triukšmas (raudonai) naudojant statistinį triukšmo aptikimą	37
4.6. pav. Segmentuoto termografinio modelio sienos tinklainė	38
4.7 pav. Pastato šiluminės energijos naudingumo eksperimentų kovo mėn. fiksavimui rezultatai	40
4.8 pav. Pastato šiluminės energijos naudingumo eksperimentų rugpjūčio mėn. fiksavimui rezultatai.....	41
4.9 pav. Pastato šilumos nuostolių skaičiavimų tikslumo palyginimas tarp skirtingų fiksavimų	41

Ivadas

Pastatai Europos Sąjungoje išskiria apie 36 % visų šiltnamio efektą sukeliančių dujų ir suvartoja 40 % visos energijos. Didžioji dalis šiltnamio efektą sukeliančių dujų yra išskiriama būtent pastato naudojimo etape. Siekiant sumažinti energijos suvartojimą ir išmetamų šiltnamio efektą sukeliančių dujų kiekį, svarbu gebėti įvertinti dabartinį pastatų energetinį naudingumą kuo tiksliau ir efektyviau. Aukštesnio energetinio efektyvumo pastatų vartotojams yra užtikrinamas geresnis terminis komfortas ir sveikata, o mažesnė priklausomybė nuo iškastinio kuro padeda šalims siekti tvarumo tikslų. Taip pat, verta paminėti, kad aukštesnio energetinio efektyvumo pastatų rinkose vertė yra didesnė dėl mažesnio energijos suvartojimo. Pastatų energetinio naudingumo vertinimas dažnu atveju reikalauja ekspertizės ir (ar) tam tikrų simuliacijų atlikimo naudojant specializuotą programinę įrangą. Remiantis termografinėmis nuotraukomis ir iš jų sudarytais taškų masyvais, galima sukurti detalias pastato skaitmenines reprezentacijas, kuriomis pasinaudojant galima analizuoti ne tik pastato geometrines savybes, bet ir jo energetines savybes bei naudingumą.

Didėjant mašininio mokymo modelių įvairovei ir kompiuterių skaičiavimų pajėgumams, vis labiau populiarėja dirbtiniu intelektu grįsti sprendimai. Dirbtinio intelekto taikymas yra taip pat aptinkamas ir pastatų energetinio naudingumo vertinimo bei jų geometrijos nustatymo uždaviniuose.

Šio darbo tikslas yra sukurti mašininio mokymų grįstą sprendimą statinių energiniam naudingumui įvertinti.

Darbui iškeliami šie uždaviniai:

1. atlikti išsamią literatūros analizę, kurios metu būtų išanalizuojami skirtingi algoritmai statinių segmentavimui taškų masyvuose;
2. atlikti išsamią esamų sprendimų analizę, kurioje skirtingi egzistuojantys sprendimai statinių energinio naudingumo vertinimui būtų palyginami tarpusavyje;
3. atlikti išsamią duomenų analizę, kurios metu būtų ištiriamos turimų duomenų charakteristikos;
4. suprojektuoti statinių energinio naudingumo vertinimo sistemą, apibrėžti sistemos panaudojimo atvejus;
5. sukurti giliuoju mokymu grįstą sprendimą statinių energinio naudingumo vertinimui atlikti;
6. išanalizuoti statinių energinio naudingumo vertinimo sprendimo rezultatus.


Darbas yra sudarytas iš uždavinio analizės, sistemos projektavimo, duomenų analizės, eksperimentų ir sistemos dokumentacijos dalių. Pastatų energetinio naudingumo vertinimo uždavinio analizės dalyje yra pagrindžiamas darbo aktualumas, apžvelgiama su užduotimi susijusi literatūra, palyginami egzistuojantys sprendimai. Sistemos projektavimo dalyje yra apibrėžiami funkciniai ir nefunkciniai sistemos reikalavimai bei reikalavimų specifikacija. Duomenų analizės dalyje yra apžvelgiami darbe naudojami duomenys, jų charakteristikos. Eksperimentų ir rezultatų dalyje yra apžvelgiami atliekami eksperimentai ir jų rezultatai, palyginami sukurto modelio rezultatai su kitų algoritmų rezultatais. Sistemos dokumentacijos dalyje yra detalizuojami sistemos veikimo principai, apžvelgiamos galimos funkcijos, sistemos įvestis ir išvestis.

1. Pastatų energinio naudingumo vertinimo uždavinio analizė

Šiame skyriuje apžvelgiama su šia tema susijusi literatūra ir programinė įranga. Taip pat, apibrėžiami sistemos reikalavimai ir pagal apibrėžtus kriterijus palyginami egzistuojantys sprendimai.


1.1. Literatūros analizė

Taškų masyvai yra plačiai naudojami pastatų skaitmenizavimo kontekste [1,2,3,4,5,6,7,8]. Laguelas [6], naudodamas iš termografinių nuotraukų sudarytus taškų masyvus, generavo pastatų BIM (angl. *Building information modelling*) modelius, kurie gali būti naudojami tikslesnei pastato būklės reprezentacijai tam tikrame laiko momente (žr. 1.1 pav.).



1.1 pav. Laguelo sugeneruotas BIM modelis, naudojantis tris skirtingas tekstūras

Minėto autoriaus teigimu, šie modeliai gali būti naudojami išvelgiant tam tikras pastato apvalkalo vietas, kurios gali kelti daugiau susidomėjimo suinteresuotoms šalims. Paivas [3] naudojo iš regimo spektro nuotraukų sudarytus taškų masyvus paveldo pastatų segmentavimui (žr. 1.2 pav.).




1.2 pav. Paivo originalaus (a), teisingai segmentuoto (b) ir segmentuotų pagal skirtingus algoritmus (c, d, e) taškų masyvų palyginimas

Autoriaus teigimu, pastato taškų masyvas yra tiksliausia skaitmeninė didelio pastato reprezentacija tam tikram laiko momentui, tačiau jo segmentavimas ar tam tikrų sudedamųjų išskyrimas yra ypač sudėtinga užduotis. To priežastis autorius įvardija:

- didelis taškų kiekis modelyje, kuris gali siekti šimtus milijonų;
- dideli taškų analizės kaštai dėl ypač didelio taškų kiekio;
- triukšmo egzistavimas dėl taškų debesies kūrimo proceso;
- neužfiksuojami taškai (skylės modelyje).


Dėl šių priežasčių yra sunku išanalizuoti taškų masyvus ir juos apdoroti siekiant atlikti įvairius pastatų skaitmenizavimo darbus. Dalis minėtų priežasčių yra tiesiogiai susijusios su taškų kiekiu masyve. Dėl ypač didelio taškų kiekio tam tikri algoritmai užtrunka ilgai apdorojant duomenis, tad greitesnis apdorojimas reikalautų daugiau skaičiavimo resursų. Kita dalis priežasčių dėl pastato sudedamųjų išskyrimo užduoties sudėtingumo yra susijusi su prasta duomenų kokybe. Prastos kokybės taškų masyvas gali susidaryti dėl tam tikrų sąlygų bet kuriame iš taškų masyvo sudarymo žingsnių. Taip pat, gali pasitaikyti atvejų, kai taškų masyvas gali būti sugeneruotas prasta kokybe dėl įvairių oro sąlygų, tokių kaip lietus, rūkas ir pan. [9]. Atliekant pastatų segmentavimą, taškų masyvuose susiduriama su skylėmis pastatų modeliuose [1] (žr. 1.3 pav.).



1.3 pav. Zango pateikti skylėtų taškų masyvų pavyzdžiai

Zangas [1] šią problemą įvardijo kaip itin svarbią dėl ypač didelės pilnų (t. y. turinčių minimalų kiekį skylių) taškų masyvų svarbos kuriant pastatų BIM modelius ir kuriant išmaniuosius miestus.


Pasak Rističos [10], termografinės nuotraukos gali būti naudojamos nustatant pastato energinį naudingumą. Minėta autorė naudojo termografines nuotraukas nustatydama vieno iš Belgrade esančių muziejų energetinį naudingumą ir įvertino, kad šio pastato energetinis naudingumas yra žemas. Naudojant įprastas nuotraukas, tokio pobūdžio tyrimo nebūtų galima atlikti dėl nuotraukose užfiksuojamos informacijos. Termografinėse nuotraukose yra užfiksuojama infraraudonųjų spindulių šviesa, kurią skleidžia visi objektai [10]. Pasak autorės, tam tikroms užduotims, kaip šiluminių ar šalčio tiltų nustatymui ar drėgmės nustatymas, nėra reikalingos itin tikslios termografinės nuotraukos (žr. 1.4 pav.).



1.4 pav. Rističos užfiksuotas šalčio tiltas, naudojant infraraudonųjų spindulių kamerą


Paveiksle matomas tamsiai mėlynas kraštas nurodo tikėtiną vandens nutekėjimą iš pastato stogo. Autorė, vizualiai įvertindama pastato energetinį naudingumą, nustatė tiek pastato konstrukcijoje susikaupusią drėgmę, tiek ir pastato šilumos laidumo savybes. Zumas [11] naudojo termografines nuotraukas, nustatydamas anomalijas ir kitus reiškinius bei charakteristikas užtvankoms Čekijos

Respublikoje. Autorius, remdamasis termografinių nuotraukų informacija, nustatė aktualias užtvankų savybes, kurias nustatyti nebūtų galima naudojant tik regimo spektro nuotraukas (žr. 1.5 pav.).



1.5 pav. Zumro darbe naudojama termografinė nuotrauka, kurioje galima matyti pažymėtus žemos paviršiaus temperatūros taškus

Kaip galima matyti nuotraukoje, tam tikrose vietose prie užtvankos yra užfiksuota žema paviršiaus temperatūra, kas, pasak autoriaus, koreliuoja su faktu, kad tuose taškuose yra aukštas viršutinio dirvožemio vandens kiekis. Rističos [10] ir Zumro [11] darbuose yra pabrėžiama, kad objektų analizė naudojant termografines nuotraukas yra vienas iš būdų nustatyti tam tikras objektų charakteristikas, tiesiogiai neįsiterpiančias į vykstančius procesus. Gil-Dokampas [12] naudojo termografinius taškų masyvus efektyvesnei pastato šiluminių charakteristikų analizei. Naudojant termografinius taškų masyvus, autorius galėjo efektyviau išvelgti ir šalčio tiltus. Termografinė informacija taškų masyvuose yra taip pat yra panaudojama ir kituose darbuose, pvz. Dleskas [13] augmentavo RGB spalvų erdvės taškų masyvą naudojant temperatūros reikšmes (1.6 pav.).




1.6 pav. Dlesko darbe naudojamas taškų masyvas, kuriame papildomai užkoduota temperatūros informacija kiekvienam taškui

Kaip galima matyti paveiksle, taškams yra priskiriama papildoma temperatūros informacija. Pasak autoriaus, augmentuotus taškų masyvus būtų galima analizuoti naudojant įvairią programinę įrangą ir integruoti į GIS, BIM ir kitas sistemas. Bisvanatas [14] sujungė termografinį taškų masyvą su pastato 3D modeliu naudojant tekstūras, kuriose buvo užkoduotos temperatūros reikšmės. Pasak autoriaus, tai yra tikslesnis būdas priskirti pastato 3D modeliui temperatūros reikšmes nei naudojant termografines nuotraukas. Pontis [15] naudojo termografinius taškų masyvus akmens masės šiluminių charakteristikų ir degradacijos stebėsenai skirtinguose metų laikuose. Zu [16] sukūrė termografinį taškų masyvą naudojant bespalvį taškų masyvą ir termografines nuotraukas. Pasak autoriaus, generuoti termografiniai taškų masyvai gali būti naudojami pastatų šiluminės energijos vertinimui, vamzdynų analizei ir energijos sąnaudų stebėsenai. Taip pat, Linas [17] bespalviams taškų masyvams priskyrė temperatūros reikšmes remiantis termografinėmis nuotraukomis tokiu būdu sudarant termografinį taškų masyvą. Autorius sudaryto taškų masyvo temperatūros reikšmes palygino su tikrosiomis paviršiaus temperatūros reikšmėmis ir nustatė, kad naudojant jo metodologiją buvo pasiektas 1,5 °C tikslumas remiantis vidutinės kvadratinės paklaidos metrika.

Vienas iš sunkumų įvertinant ir modeliuojant pastatų energetinį naudingumą yra didelės laiko sąnaudos atliekant šias užduotis [4]. Odonelo [4] teigimu, atliekant šias užduotis taip pat galima atlikti skaičiavimo, modeliavimo klaidų, kurios gali paveikti galutinį rezultatą. Autorius sprendė šią problemą sukurdamas sprendimą automatiškai segmentuoti pastato fasadų geometriją naudodamas hibridinį modelį ir siūlo naudoti segmentuotą modelį tolimesniam pastato energetinio naudingumo modeliavimui. Autoriui pavyko segmentuoti pastatų fasado elementus ir sukurti segmentuotus taškų masyvus, kuriuose kiekvienam taškui būtų priskiriama tam tikra klasė. Liuas [5], naudodamas


hibridinį modelį pastatų segmentavimui, pasiekė 4,99 % paklaidą vertinant atpažintų pastatų taškų masyve kiekį. Paivas [3] atliko paveldo pastatų segmentaciją naudodamas hibridinį algoritmą remdamasis kreivių analize ir vandenskyros transformacijomis ir pasiekė iki 48,05 % tikslumą remdamasis teisingai segmentuotų taškų kiekiu.

Tarp populiariausių taškų masyvų segmentavimo algoritmų yra RANSAC [3,18,19,20,21]. Šis neprižiūrimo (angl. *unsupervised*) mašininio mokymo algoritmas nustato taškų klasterius surandant minimalias aibes atitinkančias tam tikrus nustatytus primitivus ir yra dažnai naudojamas segmentuoti geometriškai nesudėtingas figūras kaip sienas, stogus ir t. t. [3]. Verta paminėti, kad, nors RANSAC algoritmas aukštu tikslumu atpažįsta primitivus, algoritmas dažnu atveju negali atpažinti elementų sudarytų iš kelių primityvų [3]. RANSAC algoritmas reikalauja nurodyti norimų nustatyti primityvų kiekį. Dėl šios priežasties algoritmas nėra tinkamas nustatyti pastatų paviršius platesniu mastu, t. y. esant dideliame kiekiui pastatų. Taip pat, verta paminėti, kad RANSAC algoritmas, atsitiktinai parenkant tris taškus sudarant hipotetinę plokštumą, gali parinkti tašką nepriklausantį tikrajai plokštumai [18]. Šiai problemai spręsti buvo sukurtos RANSAC algoritmo alternatyvos siekiant pagerinti algoritmo tikslumą nustatant plokštumas [18]. Tarša-Kurdi [2] palygino skirtingus taškų masyvų segmentavimo algoritmus ir pabrėžė, kad RANSAC yra vienas iš tiksliausių algoritmų šiai užduočiai atlikti. Tarp kitų dažnai aptinkamų neprižiūrimo mokymo algoritmų taškų masyvų segmentavimui yra Hough transformacija [2,22,23]. Hough transformacija suranda pikus parametrizuotoje erdvėje, atspindinčius ieškomas plokštumas taškų masyve [2]. Verta paminėti, kad algoritmas yra jautresnis parametrui nei RANSAC ir algoritmas yra lėtesnis greitaiveikos prasme [2]. Dažnu atveju šie klasikiniai algoritmai yra modifikuojami pritaikant juos specifinių plokštumų, pavyzdžiui, stogų atpažinimui (žr. 1.7 pav.).



1.7 pav. Tarša-Kurdžio stogų segmentavimas naudojant klasikinį RANSAC algoritmą mažiau tankiam (a) ir daugiau tankiam (b) taškų masyve

Paveiksle matomi nuspalvinti taškai nurodo atskiras stogo dalis, kurias nustato RANSAC algoritmas. Atpažintos plokštumos gali būti apjungiamos į visumą siekiant atpažinti norimą objektą, pavyzdžiui, statinį. Egzistuoja ir mažiau aptinkamų algoritmų ir metodų išskirti tam tikras pastatų dedamąsias. Maheris [24] išskiria pastatų langus ir šilumos tiltelius apdorojant taškams priskirtų temperatūros reikšmių histogramas (žr. 1.8 pav.).



(a)




(b)

1.8 pav. Maherio segmentuoto termografinio taškų masyvo (a) ir originalios to paties objekto nuotraukos (b) palyginimas


Kaip galima matyti paveiksle, autorius segmentavo tam tikrus fasado elementus remiantis paviršiaus temperatūros informacija taškų masyve. Jarzabekas [25] naudojo *Conditional Random Field* modelį fasadų segmentavimui taškų masyvuose ir pasiekė 92 % ir 95 % tikslumą dviems taškų masyvams vertinant pagal tinkamai nustatytą taškų kiekį. Linas [17] taikė *Region growing* algoritmą pastato plokštumų segmentacijai taškų masyvuose ir pasiekė 82 % tikslumą vertinant pagal tinkamai nustatytą taškų kiekį. Pasak autoriaus, RANSAC ir Hough transformacijos algoritmai yra apriboti dėl jų itin didelio jautrumo parametrų nustatymams ir santykinai prastos greitaveikos segmentuojant didelį kiekį plokštumų. Autorius taip pat pabrėžia, kad *Region growing* algoritmą greitaveika yra aukšta, tačiau šis algoritmas yra jautrus triukšmui.

Literatūroje yra taip pat aptinkami ir giluminiu mokymu paremti modeliai [26,27,28,29,30,31]. Šie modeliai naudoja sudėtingesnius netiesinius modelius, kaip, pavyzdžiui, neuroninius tinklus. Tomasas sukūrė konvoliucijomis paremtą modelį objektų semantiniam segmentavimui taškų masyvuose [31]. Autoriaus sukurtas modelis *KPConv* pasiekė 85,1 % tikslumą vertinant pagal *mean intersection over union* metriką naudojant *ShapeNetPart* duomenų rinkinį. Verta paminėti, kad tai yra vienas iš kelių giliuoju mokymu grįstų modelių, kuris yra realizuotas šiame darbe naudojamoje *Open3D-ML* bibliotekoje, kuri yra skirta darbui su taškų masyvais ir kitais 3D objektais [32]. Huasas [26] sukūrė daugiasluoksniais perceptronais (angl. *multi-layer perceptron*) paremtą modelį objektų semantiniam segmentavimui didelio masto taškų masyvuose (žr. 1.9 pav.).



1.9 pav. Huasaso sukurto *RandLA-Net* modelio architektūra

Autoriaus sukurta *RandLA-Net* modelio architektūra susideda iš *multi-layer perceptron*, *local feature aggregation*, *fully connected*, *random sampling*, *up-sampling* sluoksnių. Modelis segmentavimui atlikti naudoja taškų koordinates ir spalvas, taip pat buvo išmokytas ir ištestuotas naudojant *Semantic3D*, *SemanticKITTI* ir *S3DIS* duomenų rinkinius. Autorių sukurta modelis pasiekė 86,9 % tikslumą vertinant pagal *intersection over union* metriką segmentuojant pastatus, naudojant *SemanticKITTI* duomenų rinkinį. Tai yra taip pat vienas iš kelių modelių, realizuotų *Open3D-ML* bibliotekoje. Landriuas [28] taškų masyvą apdoroja kaip grafą, kuriame yra apibrėžiami ryšiai tarp skirtingų masyvo elementų taškų (žr. 1.10 pav.).




1.10 pav. Landriuo sukurtos sprendimo žingsniai

Pirma, taškų masyvas yra taškų masyvo geometrija, kuri yra paverčiama į paprastesnę geometriją supaprastinant taškų masyvą. Tada, iš šios supaprastintos geometrijos yra sudaromas grafas, kuris yra vėliau perduodamas kaip įvestis į neuroninį tinklą. Į neuroninį tinklą perduodama įvestis yra daug kartų mažesnė už pradinį taškų masyvą. Autoriaus sukurta modelis pasiekė 93,2 % tikslumą pastatų segmentavimo uždavinyje, vertinant pagal *intersection over union* metriką, naudojant *Semantic3D* duomenų rinkinį. Ducas [29] sukūrė sprendimą, kuriame taškų masyvai segmentavimo metu nėra apdorojami blokais, o naudojant jų pilną struktūrą. Autoriaus teigimu, taškų masyvų apdorojimas blokais gali padalinti taškų masyvą taip, kad jame būtų prarandama svarbi informacija. Autoriaus sukurta modelis pasiekė 80,2 % tikslumą segmentuojant 8 klases, naudojant *Toronto3D* duomenų rinkinį.

1.2. Egzistuojančių sprendimų šilumos nuostolių skaičiavimams atlikti naudojant termografinius modelius analizė

EnergyPlus yra atvirojo kodo programinė įranga, suteikianti galimybę naudotojui atlikti pastato energetinio naudingumo vertinimą. Tai yra globaliai pripažinta programinė įranga, už kurios finansavimą yra atsakingas Jungtinių Amerikos Valstijų energetikos departamentas [33]. Nors ši programinė įranga gali būti naudojama įvairioms pastato energetikos simuliacijoms atlikti, naudotojas privalo pats paruošti įvairią informaciją apie analizuojamą pastatą ir sukurti modelį


simuliacijai atlikti. Dėl šių priežasčių *EnergyPlus* programinė įranga yra labiau tinkama tais atvejais, kai apie pastatą ir jo charakteristikas yra iš anksto žinoma. Taškų masių atveju tam tikra dalis informacijos gali būti generuojama remiantis taškų masių geometrine informacija, tačiau *EnergyPlus* programinė įranga reikalauja išsamesnės informacijos apie pastato charakteristikas, jame naudojamas medžiagas, ŠVOK sistemą. Svarbus šios programinės įrangos privalumas yra jos suderinamumas su kita programine įranga (žr. 1.11 pav.).



1.11 pav. *EnergyPlus* programinės įrangos suderinamumo su kita programine įranga atvaizdavimas. Šaltinis: <https://www.energy.gov/eere/buildings/downloads/energyplus-0>

Kaip galima matyti iš paveikslo, *EnergyPlus* programinė įranga yra suderinama su įvairia kita programine įranga, tarp kurių yra *Bentley Systems AECOSim* BIM modeliavimo įrankis, *Simergy* pastatų energetinės simuliacijos karkasas, *Autodesk Insight* pastatų energetinės simuliacijos variklis ir kt.

VisionLidar programinė įranga suteikia galimybę naudotojui atlikti įvairius apdorojimo veiksmus taškų masėms: automatizuoti jų segmentavimą, plokštumų aptikimą, šalinti triukšmus ir t. t. (žr. 1.12 pav.).



1.12 pav. *VisionLidar* programinės įrangos galimybės automatiškai nustatyti žemės plokštumą taškų masėje. Šaltinis: <https://www.youtube.com/watch?v=uaTwxoPpbic>

Vizualiai vertinant galima teigti, kad programinė įranga geba tinkamai išskirti žemės plokštumą taškų masyve. Verta paminėti, kad naudojant šią programinę įrangą galima generuoti BIM modelius iš segmentuotų taškų masyvų. Programinė įranga taip pat yra suderinama su įvairia Bentley Systems ir Autodesk programine įranga, tokia kaip *Bentley MicroStation*, *Autodesk AutoCad*, *Autodesk Civil3D* ir kt. Šios programinės įrangos trūkumas yra toks, kad naudotojui nėra suteikiama galimybė panaudoti iš termografinių nuotraukų sudarytų taškų masyvų pastato energetinio naudingumo vertinimui atlikti. Abu minėti sprendimai buvo palyginti remiantis nustatytais kriterijais (žr. 1.1. lent.).


1.1 lentelė. Skirtingų egzistuojančių sprendimų palyginimas

Kriterijai	Programinė įranga	
	EnergyPlus	VisionLidar
Suteikia galimybę naudotojui segmentuoti taškų masyvus	Ne, programinė įranga nesuteikia galimybės apdoroti taškų masyvų.	Taip, programinė įranga suteikia galimybę naudotojui segmentuoti taškų masyvus naudojant automatizuotus įrankius.
Suteikia galimybę naudotojui atlikti pastato energetinio naudingumo vertinimą	Taip, suteikiama galimybė naudotojui atlikti pastato energetinio naudingumo vertinimą ir simuliacijas.	Ne, programinė įranga nėra pritaikyta pastatų energetinio naudingumui vertinti.
Užtikrina suderinamumą su kita, dažnai naudojama programine įranga	Taip, programinė įranga yra suderinama su įvairia kita programine įranga.	Taip, programinė įranga yra suderinama su įvairia kita programine įranga.

Nors nei vienas iš nagrinėtų egzistuojančių sprendimų neatitinka darbe nagrinėjamo sprendimo, tam tikri vertinimo kriterijai abiejuose sprendimuose atitinka. *EnergyPlus* programinė įranga yra plačiai naudojama pastato energetinio naudingumo vertinime ir simuliacijoms atlikti, tačiau ši programinė įranga neturi suderinamumo su taškų masyvais. *VisionLidar* programinė įranga yra tiesiogiai skirta darbui su taškų masyvais, tačiau programinė įranga neturi galimybių apdoroti termografinių nuotraukų ir atlikti pastato energetinio naudingumo vertinimo.


2. Dirbtiniu intelektu grįstos pastatų energinio naudingumo vertinimo sistemos projektavimas

Šiame skyriuje aprašoma sukurta sistema, jos panaudojimo atvejai ir funkcijos. Darbui buvo pasirinkta sukurti sistemą, kuri galėtų įvertinti pastatų energinio naudingumo skaičiavimus naudojant termografiją ir dirbtinio intelekto metodus. Sukurta sistema suteikia galimybę naudotojui atlikti statinių energetinio naudingumo skaičiavimus naudojant tam skirtas *Python* funkcijas. Naudotojo galimi veiksmai yra apibūdinami panaudojimo atvejų diagramoje (žr. 2.1 pav.).



2.1 pav. Sistemos panaudojimo atvejų diagrama


Sistemoje naudotojui suteikiama galimybė užkrauti įvesties duomenis, t. y. taškų masyvą, kuriame yra statinių objektai ir termografinės nuotraukos, iš kurių sudarytas taškų masyvas. Iš naudotojo yra tikimasi, kad įvesties duomenys yra kokybiški, priešingu atveju naudotojas gali tikėtis netenkinamos išvesties. Pirmas panaudojimo atvejis suteikia galimybę naudotojui užkrauti savo sistemoje įvesties duomenis (žr. 2.2 pav.)



2.2 pav. 1 PA „Užkrauti duomenis“ veiklos diagrama


Duomenų užkrovimo panaudojimo atvejuje yra užkraunami visi sistemoje naudojami duomenys naudojant sukurtą *DJIWrapper* klasę ir *open3d* biblioteką. Sėkmingai duomenis užkrovus tęsiamas sistemos darbas, o priešingu atveju – į komandinę eilutę yra išvedamas klaidos pranešimas naudotojui. Antras panaudojimo atvejis yra naudojamas duomenų atvaizdavimui. Jo metu yra iškviečiama *open3d* funkcija trimačiam taškų masyvo atvaizdavimui naujame lange. Šiai funkcijai galima perduoti ir papildomus parametrus duomenų atvaizdavimui jeigu naudotojas norėtų atvaizduoti kelis taškų masyvus ar kitokio tipo 3D geometriją.

Energinio naudingumo skaičiavimų atlikimo panaudojimo atvejis susideda iš statinių segmentavimo taškų masyvuose ir paviršių temperatūros duomenų paruošimo. Šis panaudojimo atvejis apima pagrindinius sistemos veiksmus (žr. 2.3 pav.).




2.3 pav. Sistemos šilumos nuostolių skaičiavimo žingsniai

Šilumos nuostolių skaičiavimai yra atliekami panaudojant termografines nuotraukas ir termografinius taškų masyvus. Statinių segmentavimas termografiniuose taškų masyvuose yra atliekamas naudojant tam skirtą modelį, kuris kaip rezultatą išveda statinių klasei priklausančius taškus (žr. 2.4 pav.).



2.4 pav. Pastatų segmentavimo įvesties ir išvesties pavyzdys taikant darbe naudojamą duomenų rinkinį


Paveiksle matomas taškų masyvas yra segmentuojamas taip, kad jame liktų tik pastatų klasei priklausantys taškai. Tolimesniuose žingsniuose šis segmentuotas taškų masyvas yra paverčiamas į tinklainę, kurią panaudojus yra apskaičiuojami atskirų tinklainės trikampių plotai ir RGB spalva (žr. 2.5 pav.).



2.5 pav. Termografinės tinklainės apdorojimo nustatant trikampių spalvą ir paviršiaus plotą pavyzdys


Kaip galima matyti paveiksle, sudarytoje tinklainėje kiekvienas trikampis turi tam tikrą geometriją. Šiame žingsnyje kiekvieno trikampio plotas yra apskaičiuojamas bei išsaugojama trikampio spalva.

Paviršių temperatūrų duomenys yra paruošiami naudojant termografines nuotraukas. Šios nuotraukos yra apdorojamos apskaičiuojant jose užkoduotas paviršiaus temperatūros reikšmes ir jas priskiriant RGB reikšmėms (žr. 2.6 pav.).



2.6 pav. Pastato paviršiaus temperatūrų iš termonuotraukų priskyrimo RGB reikšmėms vizualizacija

Kaip galima matyti paveiksle, termografinės nuotraukos yra apdorojamos priskiriant normalizuotas RGB reikšmes paviršiaus temperatūros reikšmėms. Tolimesniame žingsnyje atskirų tinklainės trikampių paviršių plotai yra pagal jų RGB reikšmę priskiriami prie tam tikros paviršiaus temperatūros reikšmės (žr. 2.7 pav.).




2.7 pav. Pastato termografinės tinklainės trikampių plotų ir temperatūrų apjungimo vizualizacija

Tinklainės trikampių paviršių plotas ir temperatūra yra apjungiami pagal artimiausią spalvą. Artimiausia spalva yra parenkama pagal trumpiausią Eulerio atstumą. Paskutiniame žingsnyje,

naudojant šias paviršiaus ploto ir temperatūros reikšmes, atliekami šilumos nuostolių skaičiavimai kiekvienam tinklainės paviršiui ir rezultatas sumuojamas.


Pastatų segmentavimo panaudojimo atvejis, kuris yra naudojamas prieš atliekant šilumos nuostolių skaičiavimus, atskiria pastatų klasei priklausančius taškus. Taškų masyvas yra segmentuojamas pagal nurodomus parametrus ir yra grąžinamas segmentuotas taškų masyvas (žr. 2.8 pav.).



2.8 pav. 4 PA „Atlikti pastatų segmentavimą taškų masyvuose“

Diagramoje yra atvaizduotas procesas nuo taškų masyvo segmentavimo iki paviršiaus plotų ir temperatūrų priskyrimo. Priskyrus kiekvienam paviršiui plotą ir temperatūrą, galima atlikti šilumos nuostolių skaičiavimus tolimesniame etape.

Sistemoje naudojami duomenys yra termografinės nuotraukos ir iš jų sudaryti termografiniai taškų masyvai (žr. 2.9 pav.).



2.9 pav. Sistemos duomenų klasių diagrama

Kaip galima matyti iš sistemos duomenų klasių diagramos, naudojamos nuotraukos yra užkraunamos kaip *PIL* bibliotekos *Image* objektai. Užkraunant duomenis šiuo būdu galima prieiti prie informacijos apie kiekvieną nuotraukos tašką ir atlikti nuotraukų konvertavimus į *numpy* bibliotekos masyvus

tolimesniems darbams. Taškų masyvai yra užkraunami kaip *Open3D* bibliotekos *PointCloud* objektai. Naudojant šią biblioteką galima apdoroti taškų masyvus ir atlikti įvairias operacijas. Darbe naudojamos *DJI* termonuotraukos yra koduojamos *JPEG* formatu, kuris leidžia pridėti papildomus metaduomenų laukus (žr. 2.1 lent.).

2.1 lentelė. Su paviršiaus temperatūra susijusių EXIF elementų iš *DJI* termonuotraukų metaduomenų aprašymas

EXIF elemento pavadinimas	EXIF elemento reikšmė
Thermal Data	Užkoduoti duomenys (655 360 baitai)
Ambient Temperature	25,0 C
Object Distance	5.0 m
Emissivity	0.95
Relative Humidity	50 %
Reflected Temperature	25.0 C
Thermal Calibration	Užkoduoti duomenys (23 818 baitai)

Kaip galima matyti lentelėje, įvairūs parametrai, skirti paviršiaus temperatūros kalibravimui ir įvertinimui, yra užkoduoti kaip *EXIF* elementai. Tokie *EXIF* elementai kaip *Thermal Data* ir *Thermal Calibration* yra užkoduoti taip, kad juos būtų galima dekoduoti tik naudojant *DJI* programinę įrangą. Likusieji parametrai yra naudojami paviršiaus temperatūros nustatymui. Naudojant *DJI Thermal SDK C++* biblioteką, šie parametrai yra perduodami į funkciją *measure*, kuri, atlikus paviršiaus temperatūros nustatymą, grąžina temperatūros reikšmių dvimatį masyvą. Siekiant atlikti įvairius skaičiavimus, naudojant paviršiaus temperatūros reikšmes ir integruoti juos į sistemą, buvo pasirinkta sukurti *Python* klases ir objektus darbui su *DJI* termonuotraukomis (toliau – *dji-wrapper*). Šios funkcijos leidžia iškviesti *C++* kodą iš *DLL* arba *SO* bylų iš *DJI Thermal SDK* įrankio naudojant *Python* programavimo kalbą.

3. Termografinių duomenų analizė

Šiame skyriuje išanalizuojami darbe naudojami duomenys ir veiksmas, kurie buvo naudojami juos paruošiant tolimesniam naudojimui darbe. Norint atlikti statinių energinio naudingumo skaičiavimus remiantis termofotogrametrija, reikalingas duomenų rinkinys, kuriame būtų termofotogrametrinis modelis ir realios paviršiaus temperatūros reikšmės. Taip pat, minėtame duomenų rinkinyje turi būti energinio naudingumo reikšmės, su kuriomis būtų galima palyginti gautus skaičiavimų rezultatus. Kadangi nėra duomenų rinkinio, kuris atitiktų šiuos kriterijus, buvo pasirinkta sukurti uždaviniui skirtą duomenų rinkinį.

Darbe naudojamas duomenų rinkinys susideda iš dviejų to paties pastato fiksavimų naudojant tą pačią termokamerą, tačiau skirtingais metų mėnesiais. Pirmasis fiksavimas buvo atliktas kovo mėnesį, šildymo sezono metu, o antras fiksavimas – rugpjūčio mėnesį, kai šildymo sezonas buvo pasibaigęs ir lauko oro temperatūra buvo didesnė (žr. 3.1 lent.).


3.1 lentelė. Darbe naudojamo duomenų rinkinio parametrai

Parametras	Kovo mėn. fiksavimas	Rugpjūčio mėn. fiksavimas
Fiksavimo laikas, h	09:49 – 10:26	01:43 – 02:21
Nuotraukų kiekis	292	362
Taškų kiekis taškų masyve	6 300 005	6 377 958
Lauko oro temperatūra, °C	0,2	22,9
Lauko oro santykinė drėgmė, %	70	69

Kaip galima matyti lentelėje, abu fiksavimai buvo atlikti naudojant panašų nuotraukų kiekį ir taškų kiekį iš termonuotraukų generuotuose taškų masyvuose yra panašūs. Kalbant apie lauko oro klimatą, santykinė drėgmė abiejų fiksavimų metu buvo panaši, tačiau temperatūra skyrėsi daugiau nei 20 °C. Atliekant šilumos nuostolių vertinimą pastatui buvo tikimasi, kad eksperimentų metu gauti rezultatai kovo mėn. būtų didesni nei rugpjūčio mėn., kadangi rugpjūčio mėn. pastatas nenaudoja šiluminės energijos šildymui. Šiame skyriuje aprašomus įvesties duomenis, t. y. termografinės nuotraukos ir termografinius taškų masyvus, teikė KTU Išmaniųjų miestų ir infrastruktūros centras.

3.1. Termografinių nuotraukų ir jų metaduomenų analizė

Termografinės nuotraukos užfiksuotos naudojant *DJI Mavic 2 Enterprise* droną. Drono užfiksuotos termografinės nuotraukos yra išsaugojamos JPEG formatu, kuriame paviršiaus temperatūros reikšmės yra išreiškiamos naudojant RGB spalvų erdvę (žr. 3.1 pav.).



3.1 pav. Atsitiktinai iš duomenų rinkinio parinktos termografinės nuotraukos

Kaip galima matyti iš paveikslo, nuotraukose skirtingi paviršiai turi skirtingas temperatūros reikšmes. Taip pat galima matyti, kad temperatūros reikšmės parinktose nuotraukose svyruoja apytiksliai nuo 35 °C iki 40 °C. Nuotraukos buvo fiksuotos kovo mėnesį. Šių nuotraukų taškų RGB reikmės gali būti dekoduojamos į paviršiaus temperatūrą naudojant ankstesniame skyriuje minėtą *dji-wrapper* (žr. 3.2 lent.).

3.2 lentelė. RGB reikšmės ir dekodauta paviršiaus temperatūra keliems atsitiktinai parinktos nuotraukos taškams


Y	X	Raudona	Žalia	Mėlyna	Paviršiaus temperatūra, °C
0	0	122	27	143	28,81
0	1	106	18	131	28,49
0	2	92	19	126	28,09
0	3	83	16	121	28,09
0	4	80	15	117	28,17
0	5	74	14	114	27,85
0	6	70	16	112	28,09
0	7	63	16	110	28,33

Kaip galima matyti lentelėje, kiekvienam nuotraukos taškui papildomai priskirta ir paviršiaus temperatūros reikšmė. Dekodavimui galima nurodyti papildomus parametrus, tarp kurių itin reikšmingas yra emisyvumas ε . ε nurodo paviršių galimybę skleisti terminę energiją ir svyruoja nuo 0 iki 1. Darbe buvo pasirinkta naudoti programinės įrangos *DJI Thermal SDK* numatytąją ε vertę – 0,95, nes daugelio matuojamų paviršių emisyvumas apytiksliai siekia tokią vertę. Verta paminėti, kad netinkamas ε parinkimas gali iškreipti nustatomą paviršiaus temperatūrą, todėl korektiškiausia parinkti skirtingą ε pagal tai, kokie paviršiai yra labiausiai aptinkami termografinėje nuotraukoje. Tarp kitų parametrų yra ir santykinė drėgmė. Papildomai nuotraukose yra užkoduojama informacija apie drono poziciją, kameros pasukimo kampą, termografinės kameros kalibravimo parametrus ir t. t. Duomenų rinkinyje yra iš viso 362 termografinės nuotraukos, kuriuose temperatūros reikšmės svyruoja tarp -10,80 °C ir 200,39 °C (žr. 3.3 lent.).

3.3 lentelė. Termografinių nuotraukų duomenų rinkinio temperatūros reikšmių metrikos

Metrika	Reikšmė, °C
Minimali reikšmė	-10,80
Maksimali reikšmė	200,39
Vidurkis	28,06
Standartinis nuokrypis	9,60
Variacija	92,22

Kaip galima matyti lentelėje, temperatūros reikšmės svyruoja itin stipriai, tačiau vidutiniška reikšmė yra arti 30 °C. Tą taip pat galima pastebėti ir *box-plot* grafike (žr. 3.2 pav.).




3.2 pav. Termografinių nuotraukų duomenų rinkinio temperatūros reikšmių *box-plot* grafikas

Kaip galima matyti iš grafiko, paviršiaus temperatūros reikšmės yra susitelkusios apytiksliai nuo 0 iki 22 °C. Grafike viršutinis ir apatinis ūseliai (angl. *whiskers*) yra 1,5 IQR (angl. *inter-quartile range*) ribose. Likusios reikšmės, t. y. reikšmės už ūselių ribų gali būti prilyginamos ekstremumams. Darbe buvo naudojamos reikšmės, kurios yra *box-plot* grafiko IQR ribose.

3.2. Termografinio taškų masyvo sudaryto iš termografinių nuotraukų analizė


Projekte naudojamas taškų masyvas buvo sudarytas naudojant *Bentley Systems ContextCapture* programinę įrangą. Ši programinė įranga suteikia galimybę generuoti fotogrametrinius modelius ir išsaugoti juos kaip 3D modelius tinklainės ar taškų masyvo pavidalu. Darbe buvo pasirinkta naudoti būtent taškų masyvo struktūrą, nes ši struktūra suteikia galimybę 3D modelį apdoroti kaip masyvą 3D erdvėje išsidėsčiusių taškų. Tai suteikia galimybę užkoduoti papildomą informaciją kiekviename taške ir suteikia galimybę apdoroti modelį naudojant įvairias itin populiarias bibliotekas, pvz. *numpy*. Verta paminėti, kad fotogrametrinius modelius generuoti naudojant termografinės nuotraukas yra sudėtingiau negu naudojant regimo spektro nuotraukas. Viena iš to priežasčių gali būti tai, kad termografinėse nuotraukose yra mažiau kontrasto tarp skirtingų *keypoints*, kurie yra naudojami nuotraukų sujungimui į vientisą modelį. Fotogrametriniai modeliai šį sujungimą atlieka automatiškai, tačiau, jeigu algoritmui atrasti šiuos *keypoints* yra sudėtinga, dėl to gali nukentėti generuojamo fotogrametrinio modelio tikslumas.

Iš ankstesniame poskyryje minėtų nuotraukų sudarytas modelis turi apytiksliai 6,4 mln. taškų, jo objektas – pastatas KTU studentų miestelyje (žr. 3.3 pav.).



3.3 pav. Duomenų rinkinyje naudojamas termofotogrametrinis modelis

Paveiksle taip pat galima matyti automobilius ir nelygų žemės paviršių. Kadangi darbo tikslas yra pastatų šilumos nuostolių skaičiavimas, šie papildomi objektai privalo būti traktuojami kaip triukšmas, kurį būtina pašalinti. Priartinus vaizdą, galima pamatyti atskirus taškų masyvą sudarančius taškus (žr. 3.4 pav.).



3.4 pav. Priartintas duomenų rinkinyje naudojamas termofotogrametrinis modelis

Kaip galima matyti paveiksle, atskiri modelio taškai yra atvaizduojami 3D erdvėje naudojant tam tikras spalvas. Informacija apie paveiksle matomus taškus yra išsaugota naudojant tam pritaiktą duomenų formatą. Šiame darbe naudojamas taškų masyvas yra išsaugotas PLY formatu. PLY formate taškų masyvui yra aprašoma antraštė (angl. *header*), kurioje yra nurodoma taškų struktūra (žr. 3.5 pav.).

```

1  ply
2  format ascii 1.0
3  element vertex 3924473
4  property float x
5  property float y
6  property float z
7  property uchar red
8  property uchar green
9  property uchar blue
10 property float nx
11 property float ny
12 property float nz
13 end_header
14 -14.776452 3.162920 129.273178 113 0 142 -0.838455 -0.544928 -0.006795
15 1.853524 -1.129042 134.591980 255 97 71 0.902381 0.430890 0.006548
16 -10.006831 4.184249 138.100433 188 40 128 -0.166262 0.481131 0.860738

```


3.5 pav. Sprendime naudojamo PLY bylos antraštė ir pirmos taškų masyvą aprašančios eilutės

Kaip galima matyti paveiksle, formate aprašoma taškų duomenų struktūra, t. y. duomenų tipai koordinatėms ir spalvoms. Taip pat yra aprašomas ir taškų kiekis bei normalės vektoriai. Tolimesnėse eilutėse aprašomi individualūs taškai, iš kurių susideda taškų masyvo struktūra. Naudojant šį duomenų formatą, galima apibrėžti papildomus parametrus, kurių reikšmes reikia priskirti kiekvienam modelio taškui. Taip pat, verta paminėti, kad PLY formato bylos gali būti užkoduojamos ASCII formatu, kaip galima matyti 3.5 pav., arba gali būti užkoduojami dvejetainiu formatu. Dvejetainiu formatu užkoduojamos PLY bylos taiko duomenų suspaudimo algoritmus informacijai

po antraštės suspausti, siekiant sumažinti bylos dydį diske. Darbe, dėl efektyvesnio bylų įskaitomumo teksto redaktoriuje, buvo naudojamos ASCII formatu užkoduojamos PLY bylos.


3.3. Termografinio taškų masyvo segmentavimo duomenų rinkinio paruošimas

Duomenų rinkinys yra sudarytas iš minėtų termografinių nuotraukų ir termofotogrametrinio modelio. Taip pat, naudojant *Supervisely* įrankį, buvo sukurti *bounding-box* objektai kiekvienai pastato plokštumai taškų masyve (žr. 3.6 pav.).



3.6 pav. Termofotogrametrinis modelis ir statinio paviršius reprezentuojantys *bounding-box* objektai

Kaip galima matyti paveiksle, *bounding-box* objektai apima pastato plokštumų taškus. Sukurto duomenų rinkinio struktūra yra apibrėžta JSON formatu kaip masyvas, susidedantis iš *bounding-box* objektų (žr. 3.7 pav.).



3.7 pav. *Bounding-box* elementas iš duomenų rinkinio sukurtas naudojant *Supervisely*

Kaip galima matyti iš paveikslo, kiekvienam *bounding-box* elementui yra priskiriama geometrinė informacija, kuri yra skirta apibrėžti objekto vieta, pasukimą ir išmatavimus trimatėje erdvėje. Šie objektai yra naudojami modelių išmokymo ir įvertinimo metu, nes jais remiantis galima tiksliai

įvertinti modelių rezultatų tikslumą. Vertinimas atliekamas tikrinant teisingai arba neteisingai pastatui priskirtus taškus. Taškų masyvo elementai priskiriami taškams yra pažymimi naudojant papildomą parametą PLY formato byloje (*true* – yra pastatas, *false* – nėra pastatas). Šis žymėjimas suteikia galimybę įvertinant rezultatus atskirti pastato klasei priklausančius taškus.

Duomenų rinkiniui nebuvo taikomos papildomos modifikacijos siekiant papildyti turimų duomenų aibę. Nuotraukų ir taškų masyvo spalvoms nebuvo atlikta augmentacija, nes spalvų reikšmės tiesiogiai priklauso nuo užfiksuotos paviršiaus temperatūros. Taip pat, nebuvo atliktos geometrinės transformacijos taškų masyvui, nes kiekvieno taško koordinatės yra susietos su realiomis objekto GPS koordinatėmis. Tokiu atveju, papildomos augmentacijos turėtų būti atliktos atsižvelgiant į šias duomenų rinkinio charakteristikas.

4. Pastatų segmentavimo termografiniuose taškų masyvuose ir energinio naudingumo skaičiavimo eksperimentai ir rezultatai

Šiame skyriuje apžvelgiami atlikti eksperimentai ir jų rezultatai. Taip pat, apibrėžiami įvairūs parametrai norint šiuos eksperimentus pakartoti naudojant darbe aptinkamą arba kitą duomenų rinkinį. Skyriuje taip pat atliekama rezultatų analizė ir palyginami skirtingi eksperimentai.

4.1. Statinių segmentavimo termografiniuose taškų masyvuose eksperimentai

Eksperimentai buvo atlikti naudojant *AMD Ryzen 3700U* procesorių ir 16 GB spartinančiosios atminties. Skirtingi algoritmai išbandyti ir palyginti naudojant skirtingas metrikas. Eksperimentuose naudojamos metrikos *Precision*, *Recall*, *F1*, *IoU*, *Chamfer distance* yra aprašytos formulėse:

$$Precision = \frac{TP}{TP + FP}; \quad (1)$$

$$Recall = \frac{TP}{TP + FN}; \quad (2)$$

$$F1 = \frac{2 \cdot TP}{2 \cdot TP + FP + FN}; \quad (3)$$

$$IoU = \frac{TP}{TP + FP + FN}; \quad (4)$$

$$d_{chamfer}(S_1, S_2) = \sum_{x \in S_1} \min_{y \in S_2} \|x - y\|_2^2 + \sum_{x \in S_2} \min_{y \in S_1} \|x - y\|_2^2; \quad (5)$$


čia *TP* – teisingai teigiamos reikšmės, *FP* – klaidingai teigiamos reikšmės, *FN* – klaidingos neigiamos reikšmės, *S₁* ir *S₂* – taškų masyvai.

Verta paminėti, kad *d_{chamfer}* metrika buvo sukurta siekiant skaitiškai įvertinti dviejų taškų masyvų panašumą. Kitos minėtos metrikos yra dažnai aptinkamos klasifikavimo uždaviniuose.

4.1.1. Statinių segmentavimas taškų masyvuose naudojant RANSAC algoritmą


RANSAC algoritmas yra skirtas apskaičiuoti matematinio modelio parametrus naudojant duomenų rinkinį, kuriame yra didžioji dalis tinkamų duomenų (angl. *inliers*) ir mažoji dalis netinkamų (angl. *outliers*) duomenų. Algoritme atsitiktinai parenkama *n* aibė taškų ir modelis yra aproksimuojamas (angl. *fitted*) pagal šią aibę. Tuomet atstumas nuo modelio iki kitų taškų yra apskaičiuojamas, taškai atitinkantys iš anksto nurodytą ribą *thres* (angl. *threshold*) yra priskiriami tinkamiems taškams. Po *n_{iter}* iteracijų modelis, turintis daugiausiai priskirtų taškų, yra atrenkamas kaip išvestis [21]. Algoritmas iteruojamas *n_{planes}* kartų, t. y. tiek kartų, iš kiek plokštumų yra sudarytas statinys.

Algoritmas išbandytas praktiškai naudojant turimus duomenis. Naudojant *Open3D* bibliotekos RANSAC implementaciją buvo atliktas plokštumų aptikimas, kurio metu buvo bandoma segmentuoti pastato sienas ir stogą nudažant jas žaliai (žr. 4.1 pav.).



4.1 pav. Du segmentuotų statinio sienų pavyzdžiai, kuriuose galima matyti tinkamai (kairėje) ir iš dalies tinkamai (dešinėje) segmentuotas statinio sienas

Pastebėta, kad nors modelis primityvios geometrijos sienas segmentuoja tinkamai, tačiau sudėtingesnės geometrijos sienas modelis segmentuoja prasčiau. Taip pat eksperimentavimo metu buvo pastebėta, kad dėl algoritmo nedeterministiškumo tam tikrais atvejais yra parenkami netinkami pradiniai taškai, dėl kurių yra nesėkmingai atliekama segmentacija (žr. 4.2 pav.).



4.2 pav. Netinkamai segmentuotos statinio sienos pavyzdys, kuriame galima matyti skylės.

Verta paminėti, kad būtų galima patobulinti algoritmo rezultatus jį kartojant n kartų ir vertinant vidutinį modelio segmentavimą kaip rezultatą, tačiau tai užtruktų n kartų ilgiau. Praeitame skyrelyje minėtoje literatūroje buvo minėta, kad RANSAC algoritmas yra dažnai modifikuojamas arba apjungiamas su kitu algoritmu. Dažnu atveju tai atliekant galima pasiekti tikslesnius rezultatus nei naudojant įprastą ir nemodifikuotą RANSAC algoritmą. Peržvelgiant algoritmo skaitinius rezultatus galima teigti, kad modelio rezultatai yra tenkinami (žr. 4.1 lent.).


4.1 lentelė. RANSAC algoritmo rezultatai naudojant $n = 3$, $n_{iter} = 1000$, $thres = 0,3$, $n_p = 7$

Parametras	Reikšmė (kovo mėn. fiksavimui)	Reikšmė (rugpjūčio mėn. fiksavimui)
<i>Precision</i>	0.45	0,60
<i>Recall</i>	0.75	0,91
<i>F1</i>	0.56	0,73
<i>IoU</i>	0.39	0,57
<i>Chamfer distance</i>	-3.14	-1,28

Kaip galima matyti lentelėje, RANSAC algoritmas veikė tiksliau naudojant fiksavimą iš rugpjūčio mėn. Nors algoritmo rezultatai yra tenkinami, jam reikia nurodyti tikslų kiekį plokštumų n_p . Galima algoritmą optimizuoti ir atrasti optimalų n_p , tačiau tai reikalautų didelio kiekio modelio iteracijų ir užtruktų ilgą laiko tarpą. Dėl šios priežasties šis algoritmas nėra tinkamas šiai užduočiai spręsti.

4.1.2. Statinių segmentavimas taškų masyvuose naudojant *RandLA-Net* modelį

Taip pat, eksperimentai buvo atlikti naudojant *RandLA-Net* modelį. Kaip galima matyti iš vizualių rezultatų, beveik visos pastato plokštumos buvo teisingai segmentuotos (žr. 4.3 pav.).



4.3 pav. *RandLA-Net* modelio segmentavimo rezultatas

Taip pat, galima pastebėti, kad modelio rezultatuose yra daug triukšmo. Automobilai, kurie matosi paveikslo dešinėje pusėje, taip pat yra segmentuoti kaip statiniai. Nors nemažą dalį triukšmo būtų galima pašalinti naudojant įvairius metodus, šio modelio rezultatai nėra tenkinami dėl modelio nesugebėjimo tinkamai segmentuoti pastato stogą. Taip pat, verta paminėti, kad yra tam tikrų neteisingo segmentavimo atvejų (pavyzdžiui, ant pastato instaliuotos įrangos), kurių nebūtų galima pašalinti naudojant paprastesnius metodus. Peržvelgiant modelio skaitinius rezultatus galima teigti, kad modelis segmentuoja statinius didesniu tikslumu kaip ir *RANSAC* algoritmas (žr. 4.2 lent.).


4.2 lentelė. *RandLA-Net* algoritmo rezultatai naudojant $bs = 4$, $lr = 0,01$, $lr_{decay} = 0,95$

Parametras	Reikšmė kovo mėn. fiksavimui	Reikmė rugpjūčio mėn. fiksavimui
<i>Precision</i>	0,64	0,67
<i>Recall</i>	0,86	0,94
<i>F1</i>	0,74	0,79
<i>IoU</i>	0,58	0,65
<i>Chamfer distance</i>	-1,50	-0,76

Nors modelio rezultatai yra tikslesni nei *RANSAC*, modelis neteisingai segmentuoja įvairius pašalinius objektus kaip statinius. Nors modelis buvo išmokytas naudojant duomenų rinkinį, kuriame buvo įtraukti ir statiniai, duomenų rinkinys naudoja regimojo spektro, o ne termografinės nuotraukas.

4.1.3. Statinių segmentavimas taškų masyvuose naudojant *KPConv* modelį

Tokiu pat principu buvo atliktas statinių segmentavimas naudojant ir *KPConv* modelį. Vizualūs segmentavimo rezultatai yra panašūs į *RandLA-Net* modelio rezultatus, tačiau juose yra mažiau triukšmo (žr. 4.4 pav.).



4.4 pav. *KPConv* modelio segmentavimo rezultatas

Žvelgiant į skaitinius segmentacijos rezultatus galima matyti, kad rezultatai yra geresni nei *RANSAC* algoritmo ir *RandLA-Net* (žr. 4.3 lent.).


4.3 lentelė. *KPConv* algoritmo rezultatai naudojant $bs = 1$, $lr = 0,01$, $lr_{decay} = 0,98477$

Parametras	Reikšmė kovo mėn. fiksavimui	Reikšmė rugpjūčio mėn. fiksavimui
<i>Precision</i>	0,71	0,68
<i>Recall</i>	0,89	0,95
<i>F1</i>	0,79	0,80
<i>IoU</i>	0,65	0,66
<i>Chamfer distance</i>	-0,47	-0,70

Gali būti, kad konvoliucijomis grįsta architektūra *KPConv* labiau tinkama segmentuojant termofotogrametrinius modelius.

4.1.4. Triukšmo šalinimas segmentuotuose taškų masyvuose

Siekiant pašalinti ankstesniuose skyreliuose minėtus triukšmus, buvo pasirinkta taikyti žinomus triukšmo šalinimo taškų masyvuose metodus. Darbe buvo pasirinkta naudoti statistinio triukšmo šalinimo algoritmą, kuris pašalina tuos taškus, kurie aplinkui savęs neturi atstume d tam tikro kiekio kaimynų K (žr. 4.5 pav.).



4.5 pav. Segmentuotas taškų masyvas, kuriame matomas aptiktas triukšmas (raudonai) naudojant statistinį triukšmo aptikimą

Kaip galima matyti nuotraukoje, dalis triukšmo buvo pašalinta. Triukšmas buvo pašalintas naudojant parametrus $K = 100$ ir $d = 0,8$. Siekiant tikslesnio šilumos nuostolių įvertinimo, taškų masyvas turi būti segmentuojamas tinkamai. Triukšmo šalinimas šiuo klausimu gali padėti pasiekti geresnius segmentavimo rezultatus (žr. 4.4 lent.).

4.4 lentelė. KPConv algoritmo rezultatai pašalinus triukšmą naudojant statistinį triukšmo šalinimą

Parametro pokytis	Reikšmė kovo mėn. fiksavimui	Reikšmė rugpjūčio mėn. fiksavimui
<i>Precision</i>	0,01	0,01
<i>Recall</i>	0,02	-0,01
<i>F1</i>	-0,04	0
<i>IoU</i>	-0.06	0
<i>Chamfer distance</i>	-0.02	0,02

Lentelėje galima pastebėti mažą segmentacijos tikslumo pagerėjimą vertinant pagal *Chamfer distance* metriką ir mažą pablogėjimą vertinant pagal *Recall* metriką.

4.2. Statinių energetinio naudingumo vertinimo eksperimentai

Pastatų energetinį naudingumą paviršiui galima įvertinti žinant jo plotą, šiluminio laidumo koeficientą, vidaus ir paviršiaus temperatūras. Šilumos energetinį naudingumą galima išreikšti per šilumos nuostolius Q :

$$Q = F \cdot A \cdot (T_i - T_p); \quad (6)$$

čia F – šilumos nuostolių koeficientas paviršiui, A – paviršiaus plotas, T_i – vidaus temperatūra ir T_p – paviršiaus temperatūra.

Šilumos nuostolių koeficientas yra nustatomas remiantis žinoma informacija apie pastato paviršiuje naudojamas medžiagas. Kadangi šiame darbe skirtingų tipų statinių paviršiai nėra nustatomi, naudojama viena F reikšmė visiems skaičiavimams atlikti.

Kadangi segmentuotas pastatas yra taškų masyvas, o ne tinklainė (angl. *mesh*), pastato modelis neturi paviršių. Sprendžiant šią problemą buvo pasirinkta taškų masyvą paversti į tinklainę naudojant dažnai aptinkamą Puasono paviršių rekonstrukcijos algoritmą [34]. Kazdano sukurtas algoritmas taškų masyvų rekonstrukcijos problemą sprendžia ją paverčiant į erdvinę Puasono problemą. Toks problemos išreiškimas suteikia galimybę rekonstrukcijos atlikimo metu atkreipti dėmesį į visų taškų padėtį erdvėje, nenaudojant jokių papildomų žingsnių, dėl kurių galutiniame rezultate galėtų atsirasti triukšmo. Naudojant šį algoritmą, taškų masyvas yra paverčiamas į tinklainę (žr. 4.6 pav.).



4.6. pav. Segmentuoto termografinio modelio sienos tinklainė

Kaip galima matyti paveiksle, atvaizduota geometrija yra sudaryta iš paviršių, kurie yra tarpusavyje apjungti sudarant tinklainę. Kiekvieno trikampio spalva yra apskaičiuojama imant trikampio kampų spalvų vidurkį. Trikampių kampų spalva ir pozicija tinklainėje atitinka taškus iš taškų masyvo. Šiame darbe energijos nuostolių skaičiavimai yra atliekami kiekvienam sudarytos tinklainės trikampiui kaip atskiram paviršiui.

Paviršiaus temperatūros reikšmės, kurios yra naudojamos formulėje, yra nustatomos remiantis 3.1. poskyryje naudojama metodologija. Kiekvieno tinklainės trikampio kampų spalvų vidurkis yra sulyginamas su paviršiaus temperatūros verte, gauta iš termografinių nuotraukų naudojant *DJI Thermal SDK* (žr. 4.5 lent.).

4.5 lentelė. Atsitiktinai parinktų tinklainės trikampių plotai ir paviršiaus temperatūros


Tinklainės trikampio plotas, m^2	Tinklainės trikampio paviršiaus temperatūra, $^{\circ}C$
0,0008	25,5305
0,0026	23,2761
0,0009	29,3719
0,0023	23,0339

Kaip galima matyti lentelėje, paviršiaus temperatūra yra priskiriama kiekvienam tinklainės trikampio plotui. Tikroji Q reikšmė buvo apskaičiuota remiantis informacija apie statinio paviršių charakteristikas. Eksperimentams buvo naudojamas taškų masyvas, kuris buvo segmentuotas naudojant *KPConv* algoritmą. Eksperimentai buvo atlikti taikant skirtingas vidaus oro temperatūros reikšmes, kadangi statinio vidaus oro temperatūra nebuvo žinoma (žr. 4.7 lent.).

4.6 lentelė. Pastato šiluminės energijos naudingumo eksperimentų kovo mėn. fiksavimui rezultatai

Vidaus oro temperatūra, $^{\circ}C$	Tikrasis Q , kW	Tikrasis Q nevertinant grindų, kW	Prognozuojamas Q , kW
20	4,08	3,39	13,86
20,5	4,16	3,46	14,15
21	4,25	3,53	14,45
21,5	4,34	3,60	14,74
22	4,42	3,67	15,03
22,5	4,51	3,75	15,33
23	4,60	3,82	15,62
23,5	4,68	3,89	15,92
24	4,77	3,96	16,21
24,5	4,85	4,03	16,50
25	4,94	4,09	16,80

Kaip galima matyti iš lentelės, skaičiavimų prognozuojamas Q yra visais atvejais didesnis už tikrą Q . Kadangi pastatų segmentavimas kovo mėn. fiksavimo taškų masyvui turi didelį kiekį triukšmo, gali būti, kad tai turėjo neigiamos įtakos rezultatams. Žvelgiant į rezultatus vizualiai galima pastebėti, kad prognozuojamo ir tikrojo Q reikšmės visais atvejais skiriasi apytiksliai 3 kartus (žr. 4.7 pav.).




4.7 pav. Pastato šiluminės energijos naudingumo eksperimentų kovo mėn. fiksavimui rezultatai

Žvelgiant į rezultatus rugpjūčio mėn. fiksavimui galima pastebėti, kad prognozuojamas Q yra tikslesnis (žr. 4.7 lent.).

4.7 lentelė. Pastato šiluminės energijos naudingumo eksperimentų rugpjūčio mėn. fiksavimui rezultatai


Vidaus oro temperatūra, °C	Tikrasis Q , kW	Tikrasis Q nevertinant grindų, kW	Prognozuojamas Q , kW
20	-0,11	-0,37	-0,69
20,5	-0,02	-0,30	-0,57
21	0,07	-0,23	-0,45
21,5	0,15	-0,16	-0,33
22	0,24	-0,09	-0,21
22,5	0,33	-0,01	-0,09
23	0,41	0,05	0,024
23,5	0,50	0,12	0,14
24	0,59	0,19	0,261
24,5	0,67	0,27	0,38
25	0,76	0,34	0,50

Kaip galima matyti lentelėje, rezultatai yra tiksliausi esant aukštesnei vidaus oro temperatūrai. Tendencija taip pat pastebima žvelgiant į rezultatus vizualiai (žr. 4.8 pav.).



4.8 pav. Pastato šiluminės energijos naudingumo eksperimentų rugpjūčio mėn. fiksavimui rezultatai

Žvelgiant į rezultatus vizualiai taip pat galima pastebėti, kad tam tikrais atvejais Q reikšmės yra neigiamos, kas gali reikšti, kad pastatas šyla. Taip pat, verta paminėti, kad nemažai šiluminės energijos yra prarandama per grindis. Kadangi taškų masyve yra užfiksuota tik pastato išorė, grindų plokštuma nėra įtraukta į skaičiavimus. Atvaizduojant šių skaičiavimų tikslumą galima pastebėti, kad šildymo sezono metu skaičiavimai yra mažiau tikslūs nepriklausomai nuo vidaus oro temperatūros (žr. 4.9 pav.).



4.9 pav. Pastato šilumos nuostolių skaičiavimų tikslumo palyginimas tarp skirtingų fiksavimų

Žvelgiant į rezultatus galima teigti, kad naudojant šią metodologiją galima atlikti itin tikslūs šilumos nuostolių skaičiavimus, tačiau rezultatus itin stipriai gali nulemti fotogrametrinio modelio kokybė, pastatų segmentavimo kokybė ir kiti faktoriai. Tikėtina, kad rezultatai pagerėtų taikant skirtingus šilumos laidumo koeficientus skirtingiems paviršiams, pavyzdžiui, langams, durims, sienoms ir t. t. Taip pat, tikėtina, kad rezultatai pagerėtų tiksliau atliekant pastatų segmentavimą, nes užfiksuotas

triukšmas, kuriame gali būti užfiksuoti įkaitę paviršiai, gali iškreipti rezultatus. Teisingą šiluminės energijos vertinimą yra sunku atlikti, nes skirtingi paviršiai turi skirtingą emisyvumą, tačiau šiame darbe konvertuojant termografines nuotraukas iš RGB reikšmių į temperatūros reikšmes buvo naudojama numatytoji emisyvumo konstanta 0,95. Siekiant pagerinti rezultatus, būtų galima atlikti konvertavimą kelis kartus taikant skirtingas emisyvumo reikšmes pagal nuotraukose aptiktus paviršius, pavyzdžiui, aptikus nuotraukoje langų ir sienų – atlikti konvertavimą du kartus, naudojant vieną emisyvumo reikšmę langams, o kitą – sienoms.

5. Dirbtiniu intelektu grįstos pastatų energinio naudingumo vertinimo sistemos dokumentacija

Šiame skyriuje pateiktos instrukcijos ir pavyzdžiai darbui su sistema. Supažindinama su diegimo procesu ir reikalavimais bei su instrukcijomis norint naudotis sistemos klasėmis.

5.1. Dirbtiniu intelektu grįstos pastatų energinio naudingumo vertinimo sistemos diegimo vadovas

Sistema susideda iš dviejų pagrindinių *Python* klasių, kurios gali vykdyti įvairias operacijas su įvesties duomenimis: *DJIWrapper* ir *ThermalLossEvaluation*. Norint naudotis šiomis klasėmis, reikia pasiruošti programavimo aplinką. Tą galima atlikti įdiegiant *Python* programavimo kalbos įrankius (mažiausiai – 3.10 versiją) ir po to įdiegiant darbui susistema reikalingas bibliotekas naudojant komandinės eilutės įrankį *pip*:

```
pip install -r requirements.txt
```

Naudojant šią komandą, įdiegiamos naujausios versijos visų bibliotekų, kurios reikalingos darbui su sistema. Jeigu naudotojas nori atlikti veiksmus su *open3d-ml* biblioteka ir naudoja Windows operacinę sistemą, reikalinga turėti paruoštą *Docker* aplinką, nes *open3d-ml* biblioteka naudoja Linux pagrindo operacinę sistemą. Sukurti darbui su *open3d-ml* tinkamą *Docker* atvaizdą galima naudojant šią komandinės eilutės komandą tame aplanke, kuriame yra *Dockerfile* byla:

```
docker build -t .
```

Ši komanda sukuria atvaizdą remiantis *Dockerfile* byloje pateiktomis instrukcijomis. Sukurtame *Ubuntu* atvaizde instaliuojama *Python* programavimo aplinka ir įvairios bibliotekos darbui su *open3d-ml* biblioteka.

5.2. Dirbtiniu intelektu grįstos pastatų energinio naudingumo vertinimo sistemos naudojimo vadovas

5.2.1. *DJIWrapper* klasės naudojimo vadovas

DJIWrapper klasė turi kelis pagrindinius metodus darbui su DJI gamintojo termografinėmis nuotraukomis (žr. 5.1 lent.).

5.1 lentelė. *DJIWrapper* klasės funkcijų aprašas

Funkcijos pavadinimas	Funkcijos aprašymas	Funkcijos parametrai	Išvesties aprašymas
<code>__init__</code>	Sukurti <i>DJIWrapper</i> klasės objektą	-	-
<code>open</code>	Atverti DJI gamintojo termografinę nuotrauką	<code>filename: str</code>	-
<code>set_measurement_params</code>	Nustatyti parametrus paviršiaus temperatūros reikšmių nustatymui	<code>params_dict: dict[str, [float, int]]</code>	-
<code>measure</code>	Nustatyti paviršiaus temperatūros reikšmes	<code>ex: bool</code>	<code>list[list[float32 int16]]</code>

get_image	Nustatyti paviršiaus temperatūros reikšmes ir atlikti triukšmo šalinimą	file_path: str bytes pathlib.Path	PIL.Image
get_df	Sukurti ir pasirinktinai išsaugoti <i>pandas.DataFrame</i> duomenų rinkinį	temp_array: list[float32 int16], monochrome: bool	pandas.DataFrame

Naudojant šiuos metodus, galima atlikti įvairias operacijas DJI termografinėms nuotraukoms, pvz. nuskaityti visas nuotraukas tam tikrame kataloge ir išsaugoti užfiksuotų paviršių temperatūros reikšmes. Detalūs, papildyti komentarais programinio kodo pavyzdžiai yra pateikti bylose *create_dataset.py*, *get_dataframe.py* ir *view_images.py*.

5.2.2. *ThermalLossEvaluation* klasės naudojimo vadovas

ThermalLossEvaluation klasė yra skirta šilumos nuostolių skaičiavimams atlikti (žr. 5.2 lent.).

5.2 lentelė. *ThermalLossEvaluation* klasės funkcijų aprašas

Funkcijos pavadinimas	Funkcijos aprašymas	Funkcijos parametrai	Išvesties aprašymas
<code>__init__</code>	Sukurti <i>ThermalLossEvaluation</i> klasės objektą	pcd: open3d.geometry.PointCloud, images: list[PIL.Image]	-
<code>segment</code>	Atlikti pastatų segmentavimą taškų masyve	pcd: open3d.geometry.PointCloud	pcd: open3d.geometry.PointCloud
<code>calculate_energy_losses</code>	Apskaičiuoti šilumos nuostolius	true_energy_losses: list[tuple[float, float]], surface_data: pandas.DataFrame	list[tuple[float, float]]

Naudojant klasę, galima iškviesti funkcijas energijos nuostolių skaičiavimams atlikti ir funkciją segmentacijai atlikti naudojant nurodytus parametrus. Detalūs programinio kodo pavyzdžiai yra pateikti byloje *thermal_loss_calculation_example.py*.

Išvados

1. Atlikta literatūros analizė parodė, kad šilumos nuostolių skaičiavimas naudojant termografinius modelius yra siaurai išnagrinėtas uždavinys mokslinėje literatūroje, o pastatų segmentavimo taškų masyvuose uždavinys, kuris svarbus vertinant pastato energinį naudingumą remiantis termografiniais taškų masyvais, dažniausiai sprendžiamas naudojant klasikinius ir giliuoju mokymu grįstus sprendimus.
2. Vertinant viešai prieinamus duomenų rinkinius nustatyta, kad nėra duomenų rinkinio, kuriame egzistuotų termografiniai taškų masyvai (įvestis) ir realūs pastatų energijos nuostoliai (palyginamoji išvestis) reikalingo šio tyrimo tikslui pasiekti. Tam tikslui buvo sukurtas naujas duomenų rinkinys, susidedantis iš dviejų to paties pastato fiksavimų kovo ir rugpjūčio mėn. pasitelkiant droną.
3. Atliktas duomenų rinkinio, susidedančio iš taškų masyvų, turinčių 12 000 000 taškų ir ~ 600 termografinių nuotraukų, paruošimas ir apdorojimas pašalinant ekstremumus.
4. Sukurti *bounding-box* elementai 7 pastato paviršiams leido atlikti efektyvesnę termografinių taškų masyvų segmentavimo rezultatų įvertinimą.
5. Suprojektuota pastatų energinio naudingumo vertinimo sistema ir pasiūlytas giliuoju mokymu grįstas sprendimas, kuris leidžia atlikti šilumos nuostolių skaičiavimus turint termografinį taškų masyvą ir termografines nuotraukas, iš kurių sudarytas termofotogrametrinis modelis (ir iš to – termografinis taškų masyvas).
6. Eksperimentiniai rezultatai parodė, kad pastatų segmentavimo žingsnyje, kuriame yra nustatoma pastato geometrija, kovo mėnesį gautas 0,68 tikslumas (vertinant ACC metriką) bei 0,71 tikslumas rugpjūčio mėnesiui. Šilumos nuostolių skaičiavimams pavyko pasiekti vidutinišką 11 kW paklaidą kovo mėn. fiksavimui ir vidutinišką 0,3 kW paklaidą rugpjūčio mėn. fiksavimui.
7. Naudojant darbe pasiūlytą metodologiją galima atlikti tikslesnius šilumos nuostolių skaičiavimus ne šildymo sezono laikotarpiu. Atliekant skaičiavimus šildymo sezono laikotarpyje sprendimas yra per jautrus šilumos nuostoliams, bet galimi šilumos nuostoliai yra užfiksuojami. Tolimesniuose darbuose būtų galima taikyti skirtingus emisyvumo ir šilumos laidumo koeficientus priklausomai nuo paviršiaus tipo. Taip pat, galima taikyti metodologiją esant daugiau nei vienam pastatui taškų masyve ir sukurti viešą, kitiems autoriams bei suinteresuotoms šalims prieinamą duomenų rinkinį šiam uždaviniui spręsti.

Literatūros sąrašas

1. ZHANG, Z. ir kt. The “Fuzzy” Repair of Urban Building Facade Point Cloud Based on Distribution Regularity. *Remote sensing (Basel, Switzerland)*. 2022, 14(5), 1090-. Prieiga per: doi: 10.3390/rs14051090.
2. TARSHA-KURDI, F. ir kt. HOUGH-TRANSFORM AND EXTENDED RANSAC ALGORITHMS FOR AUTOMATIC DETECTION OF 3D BUILDING ROOF PLANES FROM LIDAR DATA. 2007, 6.
3. PAIVA, P.V.V. ir kt. Historical building point cloud segmentation combining hierarchical watershed transform and curvature analysis. *Pattern Recognition Letters*. 2020, 135, 114–121. Prieiga per: doi: 10.1016/j.patrec.2020.04.010.
4. O'DONNELL, J. ir kt. LiDAR point-cloud mapping of building façades for building energy performance simulation. *Automation in construction*. 2019, 107, 102905-. Prieiga per: doi: 10.1016/j.autcon.2019.102905.
5. LIU, M. ir kt. Method for extraction of airborne LiDAR point cloud buildings based on segmentation. *PloS one*. 2020, 15(5), e0232778–e0232778. Prieiga per: doi: 10.1371/journal.pone.0232778.
6. LAGÜELA, S. ir kt. Automatic thermographic and RGB texture of as-built BIM for energy rehabilitation purposes. *Automation in Construction*. 2013, 31, 230–240. Prieiga per: doi: 10.1016/j.autcon.2012.12.013.
7. KAVALIAUSKAS, P. ir kt. Automation of construction progress monitoring by integrating 3D point cloud data with an IFC-based BIM model. *Buildings*. 2022, 12(10:1754), 1–19. Prieiga per: doi: 10.3390/buildings12101754.
8. DEY, E.K. ir kt. Effective Selection of Variable Point Neighbourhood for Feature Point Extraction from Aerial Building Point Cloud Data. *Remote sensing (Basel, Switzerland)*. 2021, 13(8), 1520-. Prieiga per: doi: 10.3390/rs13081520.
9. DUAN, Y. ir kt. Low-complexity point cloud denoising for LiDAR by PCA-based dimension reduction. *Optics Communications*. 2021, 482, 126567. Prieiga per: doi: 10.1016/j.optcom.2020.126567.
10. RISTIĆ, S. ir kt. Investigation of the energy efficiency of the military museum building by infrared thermography. *Vojnotehnički glasnik*. 2013, 61(2), 182–199. Prieiga per: doi: 10.5937/vojtehg61-2901.
11. ZUMR, D. ir kt. Monitoring of the soil moisture regime of an earth-filled dam by means of electrical resistance tomography, close range photogrammetry, and thermal imaging. *Environmental Earth Sciences*. 2020, 79(12), 299. Prieiga per: doi: 10.1007/s12665-020-09052-w.
12. GIL-DOCAMPO, M. ir kt. UAS IR-Thermograms Processing and Photogrammetry of Thermal Images for the Inspection of Building Envelopes. *Applied sciences*. 2023, 13(6), 3948-. Prieiga per: doi: 10.3390/app13063948.
13. DLESK, A. ir kt. USAGE OF PHOTOGRAMMETRIC PROCESSING OF THERMAL IMAGES FOR CIVIL ENGINEERS. *The International Archives of the Photogrammetry, Remote*

- Sensing and Spatial Information Sciences*. 2018, XLII–5, 99–103. Prieiga per: doi: 10.5194/isprs-archives-XLII-5-99-2018.
14. BISWANATH, M.K. ir kt. Thermal Mapping from Point Clouds to 3D Building Model Facades. *Remote sensing (Basel, Switzerland)*. 2023, 15(19), 4830-. Prieiga per: doi: 10.3390/rs15194830.
15. PONTI, S. ir kt. Thermal photogrammetry on a permafrost rock wall for the active layer monitoring. *The Science of the total environment*. 2024, 917, 170391–170391. Prieiga per: doi: 10.1016/j.scitotenv.2024.170391.
16. ZHU, J. ir kt. Fusion of urban 3D point clouds with thermal attributes using MLS data and TIR image sequences. *Infrared Physics & Technology*. 2021, 113, 103622. Prieiga per: doi: 10.1016/j.infrared.2020.103622.
17. LIN, D. ir kt. UNSUPERVISED WINDOW EXTRACTION FROM PHOTOGRAMMETRIC POINT CLOUDS WITH THERMAL ATTRIBUTES. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2019, IV-2/W5, 45–51. Prieiga per: doi: 10.5194/isprs-annals-IV-2-W5-45-2019.
18. LI, L. ir kt. An Improved RANSAC for 3D Point Cloud Plane Segmentation Based on Normal Distribution Transformation Cells. *Remote sensing (Basel, Switzerland)*. 2017, 9(5), 433-. Prieiga per: doi: 10.3390/rs9050433.
19. ADAM, A. ir kt. H-RANSAC: A HYBRID POINT CLOUD SEGMENTATION COMBINING 2D AND 3D DATA. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2018, IV–2, 1–8. Prieiga per: doi: 10.5194/isprs-annals-IV-2-1-2018.
20. XU, B. ir kt. Investigation on the Weighted RANSAC Approaches for Building Roof Plane Segmentation from LiDAR Point Clouds. *Remote sensing (Basel, Switzerland)*. 2016, 8(1), 5–5. Prieiga per: doi: 10.3390/rs8010005.
21. CHEN, H. ir kt. Plane segmentation for a building roof combining deep learning and the RANSAC method from a 3D point cloud. *Journal of electronic imaging*. 2021, 30(5), 053022–053022. Prieiga per: doi: 10.1117/1.JEI.30.5.053022.
22. LIMBERGER, F.A. - OLIVEIRA, M.M. Real-time detection of planar regions in unorganized point clouds. *Pattern Recognition*. 2015, 48(6), 2043–2053. Prieiga per: doi: 10.1016/j.patcog.2014.12.020.
23. YU, B. ir kt. A Robust Automatic Method to Extract Building Facade Maps from 3D Point Cloud Data. *Remote sensing (Basel, Switzerland)*. 2022, 14(16), 3848-. Prieiga per: doi: 10.3390/rs14163848.
24. MACHER, H. ir kt. AUTOMATION OF THERMAL POINT CLOUDS ANALYSIS FOR THE EXTRACTION OF WINDOWS AND THERMAL BRIDGES OF BUILDING FACADES. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2020, XLIII-B2-2020, 287–292. Prieiga per: doi: 10.5194/isprs-archives-XLIII-B2-2020-287-2020.
25. JARZĄBEK-RYCHARD, M. ir kt. Supervised Detection of Façade Openings in 3D Point Clouds with Thermal Attributes. *Remote sensing (Basel, Switzerland)*. 2020, 12(3), 543-. Prieiga per: doi: 10.3390/rs12030543.

26. HU, Q. ir kt. [interaktyvus]. [s.l.]: arXiv, 2020arXiv:1911.11236 [cs, eess]. Prieiga per: <http://arxiv.org/abs/1911.11236>.
27. ZHAO, Y. ir kt. A large-scale point cloud semantic segmentation network via local dual features and global correlations. *Computers & Graphics*. 2023, 111, 133–144. Prieiga per: doi: 10.1016/j.cag.2023.01.011.
28. LANDRIEU, L. - SIMONOVSKY, M. Large-Scale Point Cloud Semantic Segmentation with Superpoint Graphs. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2018, 4558–4567. Prieiga per: doi: 10.1109/CVPR.2018.00479.
29. DU, J. ir kt. ResDLPS-Net: Joint residual-dense optimization for large-scale point cloud semantic segmentation. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2021, 182, 37–51. Prieiga per: doi: 10.1016/j.isprsjprs.2021.09.024.
30. ZENG, Z. ir kt. LEARD-Net: Semantic segmentation for large-scale point cloud scene. *International Journal of Applied Earth Observation and Geoinformation*. 2022, 112, 102953. Prieiga per: doi: 10.1016/j.jag.2022.102953.
31. THOMAS, H. ir kt. [interaktyvus]. [s.l.]: arXiv, 2019arXiv:1904.08889 [cs]. Prieiga per: <http://arxiv.org/abs/1904.08889>.
32. ZHOU, Q.-Y. ir kt. [interaktyvus]. [s.l.]: arXiv, 2018arXiv:1801.09847 [cs]. Prieiga per: <http://arxiv.org/abs/1801.09847>.
33. KAMAL, R. ir kt. Strategic control and cost optimization of thermal energy storage in buildings using EnergyPlus. *Applied Energy*. 2019, 246, 77–90. Prieiga per: doi: 10.1016/j.apenergy.2019.04.017.
34. KAZHDAN, M. ir kt. *Poisson Surface Reconstruction* [interaktyvus]. . [s.l.]: The Eurographics Association, 2006 [žiūrėta 2024 m. sausio 14 d.]. ISBN 978-3-905673-24-1. Prieiga per: <https://diglib.eg.org:443/xmlui/handle/10.2312/SGP.SGP06.061-070>.
35. DLESK, A. ir kt. Photogrammetric Co-Processing of Thermal Infrared Images and RGB Images. *Sensors (Basel, Switzerland)*. 2022, 22(4), 1655. Prieiga per: doi: 10.3390/s22041655.
36. HOU, Y. ir kt. Investigation on performance of RGB point cloud and thermal information data fusion for 3D building thermal map modeling using aerial images under different experimental conditions. *Journal of Building Engineering*. 2022, 45, 103380. Prieiga per: doi: 10.1016/j.jobbe.2021.103380.

Priedai

- 1. Publikacija tarptautinei informacinių technologijų konferencijai IVUS 2024 „Building heat loss evaluation using artificial intelligence methods and thermal photogrammetry“**

Building heat loss evaluation using artificial intelligence methods and thermal photogrammetry

Justas Kardoka¹, Agne Paulauskaite-Taraseviciene¹ and Darius Pupeikis²

¹ Faculty of Informatics, Kaunas University of Technology, Studentu 50, 51368 Kaunas, Lithuania

² Faculty of Civil Engineering and Architecture, Kaunas University of Technology, Studentu 48, 51367 Kaunas, Lithuania

Abstract

Thermal point-clouds are becoming increasingly relevant in times of climate change, and it is essential that efficient methods for calculating heat losses exist. Whilst heat losses can be calculated by means of simulations and / or on-site expertise, such methods can consume significant financial resources. With the rise of artificial intelligence methods and the availability of thermal imaging technologies, they can be utilized for the automation of such calculations. We propose a methodology for calculating heat losses based on thermal photogrammetry and imaging. By segmenting thermal point-clouds for buildings and removing noise from the result of the segmentation, the output is a point-cloud that is void of unnecessary data for heat loss calculations. This model is then converted to a mesh, and heat losses are calculated for each triangle of the mesh by mapping the area of each triangle to the surface temperature of it based on the closest RGB color from the thermal images, resulting in a direct map between triangle surface area and triangle surface temperature. Our results indicate that such a methodology can be used for more efficient heat loss calculations, as we have achieved a mean average error of 0.42 kW or 0.14 kW depending on whether the ground is considered during calculations or not, respectively. Further work could explore calculating heat losses for multiple buildings at a time, calculating heat losses during different seasons. Furthermore, different emissivity and thermal loss coefficients can be used, as using static values for these parameters limits the accuracy of the calculations.

Keywords¹

Thermal photogrammetry, point-clouds, building heat loss evaluation, artificial intelligence, point-cloud segmentation, building segmentation.

Introduction

Buildings account for more than 36 % of all CO₂ emissions in the EU. For this reason, it is important to be able to evaluate the thermal losses of buildings accurately and efficiently. More thermally efficient buildings are not only more comfortable for their users, but also contribute less to greenhouse gas emissions. The detection and evaluation of thermal losses using traditional means can be expensive both in terms of time and finances. With the rise in popularity of various artificial intelligence algorithms, such tasks can be delegated at least in part to machine learning methods that can solve them efficiently.

Thermal anomalies, like cold bridges, can be detected by the use of thermal imaging [1,2]. Ristić [1] used thermal images to evaluate the thermal efficiency of a museum in Belgrade. The author concluded that the building had a low thermal efficiency and had detected several cold bridges via thermal imaging. According to the author, such phenomena can be identified even with a low-resolution thermal camera, as these points of interest are picked up due to the high sensitivity of such cameras. Zmr [2] also used thermal images for identifying thermal phenomena and other characteristics of dams in the Czech Republic. The author has identified thermal properties of the dams that would not have been possible without the use of thermal imaging hardware.

IVUS2024, May 17, 2024, Kaunas, Lithuania

EMAIL: justas.kardoka@ktu.lt (A. 1); agne.paulauskaite-taraseviciene@ktu.lt (A. 2); darius.pupeikis@ktu.lt (A. 3)

ORCID: 0000-0002-8787-3343 (A. 2); 0000-0003-3660-9339 (A. 3);



© 2024 Copyright for this paper by its authors.
Use permitted under Creative Commons License Attribution 4.0 International (CC BY 4.0).

CEUR Workshop Proceedings (CEUR-WS.org)

For digitizing buildings, point-cloud models are often used [3-10]. When it comes to analyzing and processing point-clouds, Paiva [5] had pointed out several points about the challenges for these tasks:

- Analysis of large point clouds require more resources,
- Noise can be introduced during the point-cloud creation process,
- Certain spots can be missed during the point-cloud creation process, introducing holes in the output point-cloud model.

Regarding incomplete point-cloud models, this challenge is especially noteworthy in the context of creating digital twins of buildings and cities [3]. Despite these challenges, several authors have utilized thermal models for the purpose of evaluating the thermal state of different objects. Gil-Docampo [11] used thermal photogrammetry as means of convenient building inspection, as a tool for analyzing thermal anomalies. Zhu [12] created a thermal point-cloud based on a colorless point-cloud and thermal images by mapping the pixels from the thermal images to the points in the point-cloud. Ponti [13] used thermal point-clouds for monitoring the thermal properties and degradation of a rock wall in different times of the year. Dlesk [14] augmented a RGB point-cloud with a additional dimension of data – temperature from thermal images, resulting in a point-cloud with thermal information for each point of data. Similar work was performed by Hou [15], in which they provided a framework for creating a mapping between thermal images, RGB images and colorless point-clouds. Macher [16] utilized thermal point clouds for detecting windows in building facades due to the visible thermal properties of windows when viewed through thermal images. In a similar way, Jarzabek-Rychard [17] constructed a thermal point-cloud from RGB and thermal images for the use of automatically detecting windows and other façade openings, like doors. Among other work, Biswanath [18] proposed an idea of mapping a thermal point-cloud to a 3D model of a building with the goal of enriching a building model with additional textures that represent actual surface temperature data.

In regards to calculating thermal heat losses for buildings by utilizing thermal photogrammetry, there were no identified works in which such an approach was studied, although thermal bridges and certain façade elements have been identified based on their heat print in thermal photogrammetry models.

Methodology

In our work, we propose a methodology for calculating thermal losses for buildings by using artificial intelligence methods and thermal photogrammetry. Our proposed methodology for evaluating thermal losses relies on both thermal images and point-clouds that are created by using thermal images.




Figure 1. Methodology for work, detailing the process of calculating heat loss

As can be seen in Figure 1, thermal loss evaluation was performed by acquiring specific data from thermal images and thermal point-clouds – areas of different surfaces of the building and surface temperatures for each of the surfaces. To acquire the required surfaces, outlier points must be removed from the point-cloud, such that all points left in the point-cloud should be of the building. To acquire the temperature for each of the surfaces, the RGB color of each point in the point-cloud must be mapped to a surface temperature value. The results were evaluated against a white-box model, in which the thermal losses were calculated based on the dimensions and thermal characteristics of the materials present in the building envelope. Since such a dataset does not exist (that would include true heat loss values to evaluate against), it was decided to create a custom dataset for this task.

The thermal images were captured using a DJI Mavic 2 Enterprise drone and include thermal data encoded for each pixel of the images.




Figure 2. A sample of the thermal images used in dataset.

As it can be seen from the Figure 2, the temperature in the sample images varies from about 0 to 60 °C and certain surfaces of the building are visibly heated. Due to the challenge of creating geometrically accurate photogrammetry models, it was chosen to work using images that were taken in August. For decoding the temperature data, the DJI Thermal SDK was chosen due to its' compatibility with the images taken with the drone. For decoding the temperature data using the SDK, an emissivity parameter ε must be supplied. Since the materials on the surfaces of the building in question are varied, it was chosen to use the default ε value of 0.95. In total, the dataset consists of 362 thermal images, in which, as can be seen from x, the temperature values are between -10.8 and 200 °C (see **Table 1**).

Table 1
Metrics for the thermal images in the dataset

Metric	Value, ° C
Minimum	-10.80
Maximum	200.39
Mean	28.06
Standard deviation	9.60
Variance	92.22

Since there are no publicly available point-clouds for this specific task, we have generated a thermal point-cloud from the previously mentioned images. The point-cloud was generated from a photogrammetry model that was created using Bentley Systems Context Capture (see Figure 3).




Figure 3. Thermal point-cloud used in dataset

The software takes input images and uses photogrammetry algorithms to form a 3D representation of the scene in question. As can be seen from the figure, there is a significant amount of noise surrounding the building. Much of this noise is the ground-level, which must be cleared up before pursuing building energy calculations. Additionally, there are automobiles that should not be considered during the calculations. Regarding preparing the point-cloud for further use in building energy calculations, several approaches were chosen and compared. The first approach was to use a plane segmentation algorithm for detecting and removing irrelevant planes from the point-cloud, whilst preserving planes that correspond to the building surfaces. This approach was realized via RANSAC segmentation. RANSAC is an algorithm that was originally used for finding an optimal line for a 2D dataset, but it can be adapted for finding an optimal plane in 3D space, as well. The unsupervised machine learning algorithm works by detecting clusters of points by finding the minimal sets that correspond to certain geometric primitives, like planes, roofs, etc. [5]. Another approach for segmenting the building in the point-cloud was considered – via point-cloud segmentation algorithms. There are several popular point-cloud segmentation algorithms that are capable of robust building and other object segmentation in large point-clouds. Several of the most popular algorithms are KPConv and RandLA-Net. Both algorithms are deep learning models that were trained using various point-cloud datasets. In our experiments, pre-trained models trained on the Paris-Lille3D dataset were used, as models trained on this dataset seem to perform best in segmenting thermal point-clouds.

The results of building segmentation using RANSAC, KPConv and RandLA-Net algorithms were compared using a unified benchmark. The results of the algorithms were compared to the bounding-boxes that represent the real surfaces of the building and were evaluated using different error metrics. Amongst the error metrics used, was

$$Precision = \frac{TP}{TP + FP}, \quad (1)$$

$$Recall = \frac{TP}{TP + FN}, \quad (2)$$

$$F1 = \frac{2 \times TP}{2 \times TP + FP + FN}, \quad (3)$$

$$IoU = \frac{TP}{TP + FP + FN}, \quad (4)$$

$$d_C = \sum_{x \in S_1} \min_{y \in S_2} \|x - y\|_2^2 + \sum_{x \in S_2} \min_{y \in S_1} \|x - y\|_2^2, \quad (5)$$

where TP – true positives, FP – false positives, FN – false negatives and S – point-cloud, used exclusively for comparing via Chamfer distance (see Equation 5).

The benchmark was performed using a Ryzen 3700U CPU and 16 GB of DDR4 memory. KPConv and RandLA-Net performed better than RANSAC, whilst KPConv performed best out of the three algorithms (see Table 2).

Table 2

Results of different building segmentation algorithms

Metric	RANSAC($n=3$, $n_{iter}=1000$, $thres=0.3$, $n_p=7$)	RandLA-Net($bs=4$, $lr=0.01$, $lr_{decay}=0.95$)	KPConv($bs=1$, $lr=0.01$, $lr_{decay}=0.98477$)
Precision	0.60	0.67	0.68
Recall	0.91	0.94	0.95
F1	0.73	0.79	0.80
IoU	0.57	0.65	0.66
Chamfer distance	-1.28	-0.76	-0.70

Although the building in the point-cloud was segmented, its segmentation result included a significant amount of noise, most notably – cars and other objects that have the potential to significantly skew the results of further calculations. To address this, it was chosen to statistically remove noise using K-nearest neighbors. Statistical outlier removal ensures that only points that have a certain amount of neighbors n within an average distance threshold of s remain as inliers. Statistical outlier removal was applied to the results of KPConv, which resulted in a significant number of outliers being detected (see Figure 4).




Figure 4. Segmented point cloud using KPConv, with statistical outlier removal applied afterwards

Regarding the numerical results of the outlier removal, the most significant increase in accuracy is according to the Chamfer distance (increase of 0.02), whilst there is also a small accuracy decrease according to the Recall metric (decrease of 0.01).

For retrieving the surface areas of the different surfaces of the building, the point-cloud was converted into a mesh using Poisson surface reconstruction. Poisson surface reconstruction is a robust algorithm for converting point-clouds to meshes by means of converting the task to a well-posed sparse Poisson problem, resulting in a noise-resilient algorithm [19]. Such a conversion enables analyzing the object as a collection of inter-connected triangles, each with their respective area and color. The average RGB color of the three triangle vertices is mapped by Euclidean distance to the closest temperature value from the thermal images. This results in a mapping between each triangle in the mesh and its respective surface temperature, as can be seen in Table 3.

Table 3

Sample of mesh triangles with mapped area and temperature values

Mesh triangle area, m^2	Mesh triangle surface temperature, $^{\circ}C$
0.0008	25.5305

0.0026	23.2761
0.0009	29.3719
0.0023	23.0339
0.0008	25.5305

The data can be used to calculate heat loss through the building envelope via Equation 6.

$$Q = U \times A \times (T_i - T_p); \quad (6)$$

where U is the heat transfer coefficient, A is the surface area, T_i and T_p are the indoor and outdoor temperatures.

Since we are not familiar with the indoor temperature of the building in question during the time that the thermal images were taken, different temperature values between 20 and 25 were considered. A U value of 0.202 was used, as it is a common value for walls, which is the dominant type of surface in the building. Lastly, the results of the calculations were compared to a white-box model of the building in question, in which the calculation of Q was based on known measurements of the building and its' structural materials that make up the envelope.




Figure 5. Results of heat loss calculation by using thermal point-clouds and images

As can be seen from Figure 5, the predicted Q values are close to the real Q values, especially when the ground layer (which is not visible to the drone at the time of capturing the thermal images) is not considered during calculation. The mean average error for the calculations is 0.42 kW when the ground layer is considered, and 0.14 kW when it is not.

Conclusion and further work

The most common use case for thermal point-clouds when it comes to analyzing the state of buildings – identifying cold bridges and other thermal efficiency phenomena visually. When it comes to evaluating the thermal energy loss of a building, the thermal information of the surfaces of the building envelope that is captured in the model can be used to automate this process. Since a photogrammetry-based point-cloud contains a geometrically accurate representation of the building, this can be used together with thermal information to evaluate thermal losses of the building without the need for constructing white-box models.

Since there is no publicly available dataset that could be used for such a task, we have created our own dataset utilizing 362 thermal images and a point-cloud that was created based on a thermal photogrammetry model constructed from said images. Whilst creating the dataset, we faced difficulties in creating thermal photogrammetry for the heating season, which is why thermal images and models from August were utilized. Using our approach, the point-cloud of the building is prepared by segmenting it using a pre-trained KPConv model – a deep-learning based algorithm for point-cloud segmentation and is further cleaned up by statistical outlier removal. The segmented model is then converted into a mesh via the Poisson surface reconstruction algorithm and the surface areas and colors of each of the triangles of the mesh is calculated. The color of each triangle is mapped to a surface temperature via the closest color based on the Euler distance, which results in a mapping of surface temperature value and triangle area for each of the triangles in the mesh. Lastly, this mapping is used in the calculation of thermal losses based on Equation 6.

Our approach yielded results that have a mean average error of 0.42 kW or 0.14 kW depending on if the ground is considered, or not, respectively. The results resemble the true Q values that are based on white-box simulations of the building in question. Although the results cannot be directly compared to other studies due to the custom nature of the dataset, the methodology should apply to other works if the thermal point-cloud geometry and thermal of the images accuracy are high.

For further work, it would be suggested that heat losses would be calculated for different seasons, as in our work, they were calculated only during the summer season, in which thermal losses are minimal or sometimes even negative. It is also suggested that an additional step of segmenting the different elements of the building envelope and façade should be segmented, e.g. the roof, windows, etc. and that based on this information, different ε values would be set dynamically when calculating the surface temperature from the thermal images.

References

- [1] S. Ristić, S. Polić-Radovanović, B. Jegdić, Investigation of the energy efficiency of the military museum building by infrared thermography, *Vojnotehnički Glasnik*. 61 (2013) 182–199. <https://doi.org/10.5937/vojtehg61-2901>.
- [2] D. Zúmr, V. David, J. Jeřábek, N. Noreika, J. Krása, Monitoring of the soil moisture regime of an earth-filled dam by means of electrical resistance tomography, close range photogrammetry, and thermal imaging, *Environ Earth Sci*. 79 (2020) 299. <https://doi.org/10.1007/s12665-020-09052-w>.
- [3] Z. Zhang, X. Cheng, J. Wu, L. Zhang, Y. Li, Z. Wu, The “Fuzzy” Repair of Urban Building Facade Point Cloud Based on Distribution Regularity, *Remote Sensing (Basel, Switzerland)*. 14 (2022) 1090-. <https://doi.org/10.3390/rs14051090>.
- [4] F. Tarsha-Kurdi, T. Landes, P. Grussenmeyer, HOUGH-TRANSFORM AND EXTENDED RANSAC ALGORITHMS FOR AUTOMATIC DETECTION OF 3D BUILDING ROOF PLANES FROM LIDAR DATA, (2007) 6.
- [5] P.V.V. Paiva, C.K. Cogima, E. Dezen-Kempter, M.A.G. Carvalho, Historical building point cloud segmentation combining hierarchical watershed transform and curvature analysis, *Pattern Recognition Letters*. 135 (2020) 114–121. <https://doi.org/10.1016/j.patrec.2020.04.010>.
- [6] J. O'Donnell, L. Truong-Hong, N. Boyle, E. Corry, J. Cao, D.F. Laefer, LiDAR point-cloud mapping of building façades for building energy performance simulation, *Automation in Construction*. 107 (2019) 102905-. <https://doi.org/10.1016/j.autcon.2019.102905>.
- [7] M. Liu, Y. Shao, R. Li, Y. Wang, X. Sun, J. Wang, Y. You, Method for extraction of airborne LiDAR point cloud buildings based on segmentation, *PloS One*. 15 (2020) e0232778–e0232778. <https://doi.org/10.1371/journal.pone.0232778>.
- [8] S. Lagüela, L. Díaz-Vilariño, J. Martínez, J. Armesto, Automatic thermographic and RGB texture of as-built BIM for energy rehabilitation purposes, *Automation in Construction*. 31 (2013) 230–240. <https://doi.org/10.1016/j.autcon.2012.12.013>.

- [9] P. Kavaliauskas, J.B. Fernandez, K. McGuinness, A. Jurelionis, Automation of construction progress monitoring by integrating 3D point cloud data with an IFC-based BIM model, *Buildings*. 12 (2022) 1–19. <https://doi.org/10.3390/buildings12101754>.
- [10] E.K. Dey, F. Tarsha Kurdi, M. Awrangjeb, B. Stantic, Effective Selection of Variable Point Neighbourhood for Feature Point Extraction from Aerial Building Point Cloud Data, *Remote Sensing (Basel, Switzerland)*. 13 (2021) 1520-. <https://doi.org/10.3390/rs13081520>.
- [11] M. Gil-Docampo, J.O. Sanz, I.C. Guerrero, M.F. Cabanas, UAS IR-Thermograms Processing and Photogrammetry of Thermal Images for the Inspection of Building Envelopes, *Applied Sciences*. 13 (2023) 3948-. <https://doi.org/10.3390/app13063948>.
- [12] J. Zhu, Y. Xu, Z. Ye, L. Hoegner, U. Stilla, Fusion of urban 3D point clouds with thermal attributes using MLS data and TIR image sequences, *Infrared Physics & Technology*. 113 (2021) 103622. <https://doi.org/10.1016/j.infrared.2020.103622>.
- [13] S. Ponti, I. Girola, M. Guglielmin, Thermal photogrammetry on a permafrost rock wall for the active layer monitoring, *The Science of the Total Environment*. 917 (2024) 170391–170391. <https://doi.org/10.1016/j.scitotenv.2024.170391>.
- [14] A. Dlesk, K. Vach, K. Pavelka, Photogrammetric Co-Processing of Thermal Infrared Images and RGB Images, *Sensors (Basel)*. 22 (2022) 1655. <https://doi.org/10.3390/s22041655>.
- [15] Y. Hou, M. Chen, R. Volk, L. Soibelman, Investigation on performance of RGB point cloud and thermal information data fusion for 3D building thermal map modeling using aerial images under different experimental conditions, *Journal of Building Engineering*. 45 (2022) 103380. <https://doi.org/10.1016/j.jobbe.2021.103380>.
- [16] H. Macher, T. Landes, P. Grussenmeyer, AUTOMATION OF THERMAL POINT CLOUDS ANALYSIS FOR THE EXTRACTION OF WINDOWS AND THERMAL BRIDGES OF BUILDING FACADES, *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. XLIII-B2-2020* (2020) 287–292. <https://doi.org/10.5194/isprs-archives-XLIII-B2-2020-287-2020>.
- [17] M. Jarzabek-Rychard, D. Lin, H.-G. Maas, Supervised Detection of Façade Openings in 3D Point Clouds with Thermal Attributes, *Remote Sensing (Basel, Switzerland)*. 12 (2020) 543-. <https://doi.org/10.3390/rs12030543>.
- [18] M.K. Biswanath, L. Hoegner, U. Stilla, Thermal Mapping from Point Clouds to 3D Building Model Facades, *Remote Sensing (Basel, Switzerland)*. 15 (2023) 4830-. <https://doi.org/10.3390/rs15194830>.
- [19] M. Kazhdan, M. Bolitho, H. Hoppe, Poisson Surface Reconstruction, *The Eurographics Association*, 2006. <https://doi.org/10.2312/SGP/SGP06/061-070>.