



**Kauno technologijos universitetas**

Informatikos fakultetas

**Vaizdine ir struktūrine informacija paremtų nekilnojamojo  
turto kainų prognozavimo metodų tyrimas**

Baigiamasis magistro studijų projektas

---

**Jonas Gaigalas**

Projekto autorius

**doc. Andrius Kriščiūnas**

Vadovas

---

**Kaunas, 2025**



**Kauno technologijos universitetas**

Informatikos Fakultetas

# **Vaizdine ir struktūrine informacija paremtų nekilnojamojo turto kainų prognozavimo metodų tyrimas**

Baigiamasis magistro studijų projektas

Dirbtinio intelekto informatika (6211BX007)

---

**Jonas Gaigalas**

Projekto autorius

**doc. Andrius Kriščiūnas**

Vadovas

**doc. Tautvydas Fyleris**

Recenzentas

---

**Kaunas, 2025**



**Kauno technologijos universitetas**

Informatikos Fakultetas

Jonas Gaigalas

## **Vaizdine ir struktūrine informacija paremtų nekilnojamojo turto kainų prognozavimo metodų tyrimas**

Akademinio sąžiningumo deklaracija

Patvirtinu, kad mano, Jono Gaigalo, baigiamasis projektas tema „Vaizdine ir struktūrine informacija paremtų nekilnojamojo turto kainų prognozavimo metodų tyrimas“ yra parašytas visiškai savarankiškai ir visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

Aš suprantu, kad išaiškėjus nesąžiningumo faktui, man bus taikomos nuobaudos, remiantis Kauno technologijos universitete galiojančia tvarka.

---

(vardą ir pavardę įrašyti ranka)

---

(parašas)



**Kauno technologijos universitetas**  
Informatikos fakultetas

## **Baigiamojo magistro projekto užduotis**

Projekto tema Vaizdine ir struktūrine informacija paremtų nekilnojamojo turto kainų prognozavimo metodų tyrimas

Reikalavimai ir sąlygos  
(tikslinti pavadinimą  
pagal poreikį)

Vadovas / Vadovė

\_\_\_\_\_  
(vadovo pareigos, vardas, pavardė, parašas)

\_\_\_\_\_  
(data)

Gaigalas, Jonas. Vaizdine ir struktūrine informacija paremtų nekilnojamojo turto kainų prognozavimo metodų tyrimas. Magistro studijų baigiamasis projektas / vadovas doc. Andrius Kriščiūnas; Kauno technologijos universitetas, Informatikos fakultetas.

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

Reikšminiai žodžiai: mašininis mokymasis, konvoliuciniai neuroniniai tinklai, modelių asamblėja, nekilnojamo turto kainos prognozavimas.

Kaunas, 2025. 53 p.

### Santrauka

Atlikto tyrimo tikslas buvo pagerinti nekilnojamojo turto (NT) kainų prognozavimo tikslumą, pasitelkiant struktūrinius duomenis ir vaizdinę informaciją iš NT skelbimų. Tradiciniai prognozavimo metodai dažnai nepakankamai tiksliai įvertina NT kainą dėl ribotų galimybių apdoroti įvairaus tipo informaciją. Siekiant išspręsti šią problemą, tyrimo metu buvo sukurta modelių asamblėja, apjungianti kambarių tipų klasifikavimą, turto brangumo lygio nustatymą, geometrinę gylio informaciją bei regresinį modelį į vieną sistemą.

Kambarių tipų klasifikavimui buvo pritaikytas *Vision Transformer (ViT)* modelis su *vit\_base\_patch16\_224* architektūra, pasiekęs aukštą 97.98 % tikslumą. Brangumo lygiui prognozuoti naudotas *ResNet34* modelis, kuris, nors ir pasiekė žemesnį 41.58 % tikslumą, suteikė reikšmingos informacijos. Gylio metrikos buvo gautos naudojant *Depth-Anything-V2-Metric-Indoor-Large-hf* modelį, leidusį atlikti gylio prognozes ir išgauti nuotraukų gylio informaciją.

Galutiniam NT kainų prognozavimui buvo pritaikytas *XGBoost* modelis. Tyrimo rezultatai parodė, kad struktūrinių ir vaizdinių duomenų derinimas leidžia pagerinti prognozavimo tikslumą. Naudojant tik struktūrinius duomenis (H), buvo gautas  $RMSE = 74\ 515.95$  ir  $R^2 = 0.8448$ . Brangumo lygio informacijos įtraukimas (H + L) leido pagerinti  $RMSE = 68\ 109.46$  ir  $R^2 = 0.8703$ , tai leidžia suprasti, kad vaizdiniai duomenys suteikia atitinkamą prognozės patikslinimą. Šie rezultatai patvirtina, kad vizualus kontekstas yra svarbus, kai atitinkami struktūriniai duomenys yra nežinomi.

Gaigalas, Jonas. An Investigation of Real Estate Price Prediction Methods Based on Visual and Structural Information. Master's thesis / supervisor doc. Andrius Kriščiūnas; Kaunas University of Technology, Faculty of Informatics.

Field of study and area (group of study fields): Computer science, Informatics (B01).

Keywords: machine learning, convolutional neural networks, model assembly, real estate price forecasting.

Kaunas, 2025. 53.

### Summary

The aim of this study was to improve the accuracy of real estate price prediction by leveraging both structured data and visual information extracted from property listings. Traditional prediction methods often fall short in accurately estimating real estate prices due to their limited capacity to process diverse data types. To address this issue, a model ensemble was developed, integrating room type classification, property price level estimation, geometric depth information, and a regression model into a unified system.

For room type classification, the *Vision Transformer (ViT)* model with the *vit\_base\_patch16\_224* architecture was used, achieving a high accuracy of 97.98%. To predict the price level, the *ResNet34* model was implemented, which, despite attaining a lower accuracy of 41.58%, contributed valuable information. Depth metrics were obtained using the *Depth-Anything-V2-Metric-Indoor-Large-hf* model that aided with depth predictions and the extraction of geometric characteristics from images.

The final real estate price prediction was conducted using the *XGBoost* model. The study's findings indicate that combining structured and visual data enhances prediction accuracy. Using only structured data (H) resulted in  $RMSE = 74\ 515.95$  and  $R^2 = 0.8448$ . Incorporating price level information (H + L) improved the results to  $RMSE = 68\ 109.46$  and  $R^2 = 0.8703$ , demonstrating that visual data provides a meaningful refinement to the predictions. These outcomes confirm the significance of visual context, particularly when certain structured data is unavailable or limited.

## Turinys

<b>Lentelių sąrašas .....</b>	<b>8</b>
<b>Paveikslų sąrašas .....</b>	<b>9</b>
<b>Santrumpų ir terminų sąrašas .....</b>	<b>10</b>
<b>Įvadas.....</b>	<b>11</b>
<b>1. Nekilnojamojo turto kainų prognozavimo dirbtinio intelekto metodais literatūros apžvalga .....</b>	<b>12</b>
1.1. Atsitiktinių miškų pritaikymas nekilnojamojo turto kainoms prognozuoti.....	12
1.2. Tiesinės regresijos pritaikymas nekilnojamojo turto kainoms prognozuoti.....	13
1.3. Neuroninių tinklų pritaikymas nekilnojamojo turto kainoms prognozuoti .....	13
1.4. Gradientinio stiprinimo metodai nekilnojamojo turto kainoms prognozuoti .....	14
1.5. Konvoliuciniai neuroniniai tinklai nekilnojamojo turto kainoms prognozuoti .....	15
1.6. Gylio metrikų įvertinimas iš vieno vaizdo kadro .....	16
1.7. Modelių asamblėjos pritaikymas nekilnojamojo turto kainoms prognozuoti .....	17
1.8. Problemos formulavimas.....	17
<b>2. Nekilnojamojo turto kainų prognozavimo proceso metodologija.....</b>	<b>18</b>
2.1. NT kainų prognozavimo etapai .....	18
2.1.1. Pirmasis etapas – kambarių tipų klasifikacija .....	18
2.1.2. Antrasis etapas – kambarių brangumo lygių klasifikacija.....	19
2.1.3. Trečiasis etapas – kambarių gylio įvertinimas .....	21
2.1.4. Ketvirtasis etapas – NT kainų įvertinimas pagal struktūrinius ir vaizdinius požymius .....	22
2.2. Modelių asamblėja.....	23
2.3. Modelių vertinimo metrikos .....	25
2.4. Modelių asamblėjos klaidų kaskada .....	26
2.5. Metodologijos apibendrinimas .....	27
<b>3. Nekilnojamojo turto kainų prognozavimo eksperimentai.....</b>	<b>28</b>
3.1. Kambarių tipo klasifikavimas.....	28
3.2. Kambarių brangumo lygio įvertinimas.....	31
3.3. Gylio žemėlapių kūrimas.....	35
3.4. Prognozavimas pagal struktūrinius ir vaizdinius duomenis .....	37
<b>4. Nekilnojamojo turto kainų prognozavimo rezultatų apžvalga .....</b>	<b>45</b>
<b>Išvados .....</b>	<b>47</b>
<b>Literatūros sąrašas .....</b>	<b>49</b>
<b>Priedai.....</b>	<b>52</b>
1 priedas. Požymių grupės ir sudedamieji požymiai .....	52
2 priedas. Svarbiausi požymiai.....	53

## Lentelių sąrašas

<b>1 lentelė.</b> Kambarių tipų klasifikavimo eksperimentų rezultatai .....	29
<b>3.2 lentelė.</b> Kambarių brangumo klasifikavimo eksperimentų rezultatai .....	32
<b>3.3 lentelė.</b> NT kainų statistiniai rodikliai .....	38
<b>3.4 lentelė.</b> Modelio rezultatų apžvalga .....	40
<b>3.5 lentelė.</b> NT kainų statistiniai rodikliai .....	41
<b>3.6 lentelė.</b> Modelio rezultatų apžvalga pašalinus NT objektų koordinates kokybiškiems skelbimams .....	41
<b>3.7 lentelė.</b> Modelio rezultatų apžvalga pašalinus NT objektų vietovės informaciją kokybiškiems skelbimams .....	42
<b>4.1 lentelė.</b> Geriausias kambarių klasifikavimo modelis .....	45
<b>4.2 lentelė.</b> Geriausias brangumo lygių klasifikavimo modelis .....	45
<b>4.3 lentelė.</b> Apibendrinti kokybiškų duomenų struktūriniai ir vaizdinių požymių rezultatai .....	45
<b>4.4 lentelė.</b> Svarbiausi požymiai iš kokybiškų duomenų prognozės.....	53

## Paveikslų sąrašas

<b>1 pav.</b> Atsitiktinių medžių metodo veikimo principas [6] .....	12
<b>2 pav.</b> Dirbtinio neuroninio tinklo architektūra [16] .....	14
<b>3 pav.</b> <i>XGBoost</i> algoritmo veikimo principas [20] .....	15
<b>4 pav.</b> Klasikinė konvoliucinio neuroninio tinklo struktūra [25] .....	16
<b>5 pav.</b> Pagrindiniai metodologijos etapai .....	18
<b>6 pav.</b> Kambarių tipų klasifikavimo procesas .....	19
<b>7 pav.</b> Kambarių brangumo lygių klasifikavimo procesas .....	20
<b>8 pav.</b> Kambarių gylio įvertinimo procesas .....	21
<b>9 pav.</b> Sudaryto gylio modelio koncepcija 3D erdvėje [35] .....	22
<b>10 pav.</b> NT kainų įvertinimo procesas pagal struktūrinius ir vaizdinius požymius .....	23
<b>11 pav.</b> Modelių asamblėja .....	24
<b>12 pav.</b> <i>REI</i> duomenų rinkinio klasės .....	28
<b>13 pav.</b> <i>REI</i> duomenų rinkinio klasių pasiskirstymo diagrama .....	29
<b>14 pav.</b> Geriausių kambarių tipų klasifikavimo modelių palyginimo diagrama .....	31
<b>15 pav.</b> Svetainės brangumo lygių duomenų rinkinio pavyzdžiai .....	32
<b>16 pav.</b> Geriausių brangumo lygių klasifikavimo modelių palyginimo diagrama .....	34
<b>17 pav.</b> Kiekvieno kambario tipo sumaišties matricos reprezentuojančios brangumo lygius .....	34
<b>18 pav.</b> Maišos matrica reprezentuojanti brangumo lygi .....	35
<b>19 pav.</b> Kambario vaizdas, pateiktas NT skelbime .....	36
<b>20 pav.</b> Kambario apskaičiuotas gylio žemėlapis .....	37
<b>21 pav.</b> Sudarytas kambario 3D taškų debesies modelis iš skirtingų perspektyvų .....	37
<b>22 pav.</b> NT skelbimų šilumos žemėlapis .....	38
<b>23 pav.</b> Nekilnojamojo turto kainų pasiskirstymo histograma .....	38
<b>24 pav.</b> Struktūrinių ir vaizdinės informacijos požymių koreliacijos matrica .....	39
<b>25 pav.</b> Nekilnojamojo turto kokybiškų duomenų kainos pasiskirstymo histograma .....	41
<b>26 pav.</b> Aukštos kokybės duomenų rinkinio svarbiausi požymiai .....	43
<b>27 pav.</b> Apibendrintos požymių grupės .....	52
<b>28 pav.</b> Apibendrinti gylio požymiai .....	52

## Santrumpų ir terminų sąrašas

### Santrumpos:

**MM** – mašininis mokymasis (*angl. „Machine Learning“*)

**SVM** – atramos vektorių mašinos (*angl. „Support Vector Machines“*)

**CNN** – konvoliuciniai neuroniniai tinklai (*angl. „Convolutional Neural Networks“*)

**ACC** – patikimumas (*angl. „Accuracy“*)

**PREC** – tikslumas (*angl. „Precision“*)

**NT** – nekilnojamasis turtas

**H** – struktūriniai požymiai

**L** – brangumo lygiai

**D** – gylio požymiai

### Terminai:

**Mašininis mokymasis** – dirbtinio intelekto sritis, kurioje kompiuteriai, naudodami pateiktus duomenis, savarankiškai mokosi atpažinti dėsningumus ir priimti sprendimus be tiesioginio programavimo, taip tobulindami savo veikimą bei prognozių tikslumą.

**Konvoliucinis neuroninis tinklas** – neuroninių tinklų tipas, naudojamas vaizdiniais duomenimis analizuoti ir klasifikuoti, taikant konvoliucinius sluoksnius.

## Įvadas

Sparčiai besivystančiame technologijų pasaulyje įvairių žmogaus veiklos sektorių ir technologijų sankirta tampa vis labiau akivaizdi. Tai galima pastebėti nekilnojamojo turto srityje – pramonėje, kuri tradiciškai remiasi empirinėmis žiniomis ir istoriniais duomenimis [1]. Tačiau šiame sektoriuje mašininio mokymosi metodų taikymas pradeda keisti turto vertinimą dėl galimybės turėti prieigą prie didelių duomenų kiekių bei galingų mašininio mokymosi metodų [2]. Šis tyrimas orientuotas į šių metodų taikymą prognozuojant nekilnojamojo turto kainas, kadangi tiksliai nekilnojamojo turto vertės prognozė yra svarbi tiek investuotojams, tiek namų savininkams. Tradiciniai kainų nustatymo metodai, dažnai paremti paprastais regresijos modeliais ir subjektyvia patirtimi, neretai nepajėgia susidoroti su nuolat besikeičiančia rinkos dinamika. Šiame darbe teigiama, kad mašininis mokymasis, sugebantis analizuoti didelius duomenų kiekius ir identifikuoti sudėtingus požymių ryšius, gali pasiūlyti tikslesnę ir dinamiškesnę požiūrį į nekilnojamojo turto kainų prognozavimą.

Dirbtinio intelekto metodai taip pat yra pranašesni už daugelį griežtų analitinių modelių, nes gali apdoroti tiek kokybinius, tiek kiekybinius duomenis [3]. Tokie metodai gali pateikti tikslesnes ir patikimesnes nekilnojamojo turto vertės prognozes, nes pasižymi gebėjimu veikti net ir tada, kai nėra tiesioginio matematinio ryšio tarp priežasties ir pasekmės. Šio darbo tikslas – išnagrinėti įvairius mašininio mokymosi metodus, taikomus nekilnojamojo turto kainų prognozavimui ir įvertinti jų tikslumą, efektyvumą bei pritaikomumą realioms rinkos sąlygoms. Taip pat siekiama išsiaiškinti, kaip šie dirbtinio intelekto algoritmai gali pakeisti nekilnojamojo turto vertinimo procesą. Tyrimas apima ne tik pagrindinius regresijos modelius, bet ir kitus įvairius mašininio mokymosi metodus, kaip neuroninius tinklus bei jų įvertinimą prognozuojant nekilnojamojo turto kainas.

Pagrindinis magistro darbo tikslas – išanalizuoti ir įvertinti įvairių struktūrizuotų ir vaizdinių duomenų svarbą, identifikuoti kritinius rodiklius, atlikti įvairių mašininio mokymosi metodų analizę bei sukurti modelių asamblėją, galinčią įvertinti nekilnojamojo turto kainą. Taip pat bus įvertintas modelių tikslumas, kai naudojami tik struktūrizuoti arba vaizdiniai duomenys bei bus iširtas struktūrizuoto modelio tikslumo pokytis, kai naudojama vaizdinė informacija.

Darbo tikslui pasiekti apibrėžti pagrindiniai uždaviniai:


1. nekilnojamojo turto duomenų rinkinio sudarymas, analizė ir duomenų kokybės gerinimas;
2. reikšmingų požymių sudarymas iš nekilnojamojo turto skelbimų nuotraukų;
3. mašininio modelių tikslumo analizė, kai prognozavimas yra atliekamas pagal struktūrizuotus ir vaizdinius duomenis;
4. struktūrizuotų duomenų modelio tikslinimas, naudojant vaizdinę skelbimo informaciją bei įvairių požymių grupių įtakos nekilnojamojo turto kainos prognozavimui įvertinimas;
5. modelių asamblėjos sukūrimas, gebančios įvertinti nekilnojamojo turto kainą pagal pateiktą įvairią skelbimo informaciją;
6. reikšmingų rodiklių, kurie daro didžiausią įtaką nekilnojamojo turto kainos prognozei, identifikavimas ir analizė.

## 1. Nekilnojamojo turto kainų prognozavimo dirbtinio intelekto metodais literatūros apžvalga

Mašininis mokymasis yra viena iš dirbtinio intelekto sričių, kuri padeda efektyviai spręsti kompleksinius duomenų analizės ir prognozavimo uždavinius, ypač kai kalbama apie daugiamačius ar didelės apimties duomenų rinkinius [5]. Šiuolaikiniai mašininio mokymosi algoritmai, mokydamiesi iš istorinės informacijos, leidžia aptikti reikšmingus dėsningumus bei ryšius, suteikdami galimybę geriau suprasti įvairias tendencijas. Tolesniuose literatūros apžvalgos skyriuose bus aptariama, kokias galimybes mašininis mokymasis suteikia nekilnojamojo turto srityje bei kokie galimi iššūkiai, kai yra taikomi įvairūs dirbtinio intelekto metodai.

### 1.1. Atsitiktinių miškų pritaikymas nekilnojamojo turto kainoms prognozuoti

Atsitiktinis miškas yra vienas iš populiariausių mašininio mokymosi metodų, kuris naudoja sprendimo medžius atliekant prognozavimą. Šis metodas gali būti pritaikytas ir nekilnojamojo turto kainų prognozavimui dėl savo gebėjimo apdoroti daugiamačius duomenų rinkinius. Kadangi atsitiktinių miškų metodas sukuria daugybę nepriklausomų sprendimo medžių, kurių kiekvienas yra sudaromas iš skirtingo duomenų poaibio, metodas išvengia per didelio persimokymo ir pasiekia aukštą vidutinišką tikslumą. Modelio architektūros abstrakcija yra pateikta (žr. **1 pav.**).



**1 pav.** Atsitiktinių medžių metodo veikimo principas [6]

Vienas iš reikšmingiausių atsitiktinių miškų metodo privalumų yra atsparumas triukšmui ir gebėjimas apdoroti didelių apimčių duomenų rinkinius. Taip pat atsitiktinių miškų metodas leidžia įvertinti kiekvieno kintamojo svarbą prognozuojant tikslinę reikšmę, o tai yra ypač naudinga nustatant veiksnius, kurie daro didžiausią įtaką prognozavimui [7]. Atliktuose tyrimuose, kuriuose nagrinėjami įvairūs mašininio mokymosi modeliai, kaip atsitiktiniai miškai, neuroniniai tinklai ir atraminių vektorių mašinos (SVM), buvo pastebėta, kad atsitiktinių miškų paremti metodai sugeba nuosekliausiai pasiekti pakankamai gerus rezultatus dėl gebėjimo valdyti hiperparametrus [7, 8].

Naudojant atsitiktinių miškų metodą būsto kainoms prognozuoti, buvo patvirtinta, kad metodas yra efektyvus, kai yra naudojami daugiamačiai duomenų rinkiniai [7]. Taip pat, remiantis panašiais atliktais tyrimais, buvo pastebėta, kad atsitiktinių medžių metodą pritaikius nekilnojamojo turto kainoms prognozuoti buvo gaunami rezultatai, kurie yra geriau paaiškinami lyginant su kitais modeliais, kaip neuroniniais tinklais [9]. Todėl atsitiktinių miškų metodas dažnai pritaikomas praktinėse nekilnojamojo turto srityse [10].

Tyrimai taip pat aptaria, kad įtraukus įvairius rodiklius, kaip gyventojų tankį, regioninės plėtros metrikas ir infrastruktūros kokybę, galima reikšmingai padidinti prognozavimo tikslumą. Kadangi

metodas sugeba atsirinkti svarbiausius požymius ir yra atsparus triukšmui, kurį gali sukelti pertekliniai požymiai, metodas yra tinkamas naudoti įvairiame ekonominiame kontekste ir su dideliu požymių skaičiumi [7, 10]. Atsitiktiniai miškai taip pat pasižymi gebėjimu tvarkytis su sezoniškumo veiksniais ir laiko priklausomybėmis, kurie dažniausiai sukelia iškraipymus tradiciniuose regresijos modeliuose [10].

## **1.2. Tiesinės regresijos pritaikymas nekilnojamojo turto kainoms prognozuoti**

Tiesinė regresija yra vienas iš paprasčiausių ir plačiausiai naudojamų statistinių metodų, siekiant nustatyti tiesinį ryšį tarp priklausomo kintamojo ir vieno ar kelių nepriklausomų kintamųjų. Dėl metodo aiškios interpretacijos ir gana paprasto matematinio sudėtingumo, tiesinė regresija dažnai naudojama nesudėtingiems rinkos tyrimams, išvalgų paieškai ar prognozavimo uždaviniams. Tačiau kompleksinėse situacijose, tokiose kaip nekilnojamojo turto kainų prognozavimas, šis metodas gali nepakankamai gerai aprašyti netiesinius ryšius tarp įvairių veiksnių [11].


Nepaisant šių apribojimų, tiesinė regresija išlieka naudinga, kai siekiama greitai įvertinti pagrindines priklausomybes ir patikrinti, ar tarp kintamųjų egzistuoja aiškus tiesinis ryšys. Atliktame tyrime buvo nustatyta, kad šis metodas gali pateikti vertingų išvalgų apie tiesioginį kainos bei pagrindinių būsto charakteristikų ryšį, nors sudėtingesni modeliai, kaip atsitiktiniai miškai, gali pasiūlyti didesnę tikslumą [12]. Kitame tyrime, analizuojant tiesinės regresijos palyginimą su aptinkamais regresiniais modeliais, padaryta išvada, kad tiesinė regresija tinkama tik pradinėms prognozėms, siekiant įvertinti mašininio mokymosi modelių pritaikomumą duomenų rinkiniui [13].

Taikant giliojo mokymosi modelius, galima pasiekti ženkliai didesnę tikslumą nei naudojant tradicinę tiesinę regresiją, ypač dirbant su didelio heterogeniškumo duomenimis [14]. Tyrimas apie NT nuomos rinkos pokyčius parodė, kad tiesiniai modeliai padeda suprasti ir įvertinti investuotojų lūkesčių bei NT rinkos pokyčių ryšį [15].

Nepaisant šių apribojimų, tiesinė regresija visgi gali būti reikšminga NT tyrimų srityje, ypač kaip pradiniam etapui skirtas metodas, kuriuo remiantis identifikuojami bendri rinkos dėsniumai. Tačiau norint tiksliau prognozuoti NT kainas, reikėtų rinktis sudėtingesnius mašininio mokymosi metodus, nes tiesinės regresijos pobūdžio algoritmai dažnai nesugeba įvertinti įvairių ryšių daugiamatiniuose duomenų rinkiniuose [13].

## **1.3. Neuroninių tinklų pritaikymas nekilnojamojo turto kainoms prognozuoti**

Neuroniniai tinklai yra dirbtinio intelekto metodas, imituojantis žmogaus smegenų veikimą, kuris leidžia atpažinti sudėtingus duomenų tendencijas ir atlikti tikslias prognozes. Jie ypač naudingi dirbant su dideliais ir sudėtingais duomenų rinkiniais, kuriuose yra daug tarpusavyje susijusių kintamųjų. Pagrindinis neuroninių tinklų pranašumas yra jų gebėjimas mokytis iš duomenų ir atlikti tikslias prognozes net esant triukšmui ar netiesiniams ryšiams. Modelio architektūros abstrakcija yra pateikta (žr. **2 pav.**).



**2 pav.** Dirbtinio neuroninio tinklo architektūra [16]

Atlikti tyrimai rodo, kad neuroniniai tinklai sėkmingai pritaikomi nekilnojamojo turto kainoms prognozuoti. Atliktuose tyrimuose buvo naudojami giliojo mokymosi metodai, įskaitant neuroninius tinklus, siekiant prognozuoti būsto kainas, pasitelkiant įvairius duomenų šaltinius, tokius kaip tekstiniai aprašymai ir vaizdai [17]. Gautieji rezultatai atskleidė, kad tokie modeliai gali surasti sudėtingus netiesinius ryšius, kurie leido pasiekti aukštą prognozavimo tikslumą. Kitas tyrimas, kuris pristatė Kolmogorovo-Arnoldo tinklus (KAN), teigė, kad Kolmogorovo-Arnoldo teoremą galima pritaikyti nekilnojamojo turto kainoms prognozuoti ir parodė aukštesnį tikslumą lyginant su tradiciniais metodais [14].

Viename iš atliktų tyrimų buvo taikomi gilieji neuroniniai tinklai kartu su pagrindinių komponentų analize, siekiant prognozuoti nekilnojamojo turto kainas [18]. Taip pat buvo naudojami neuroniniai tinklai kartu su genetiniais algoritmais [19]. Šie tyrimai pabrėžia neuroninių tinklų potencialą prognozuojant nekilnojamojo turto kainas, kai jie yra derinami su įvairiais metodais.

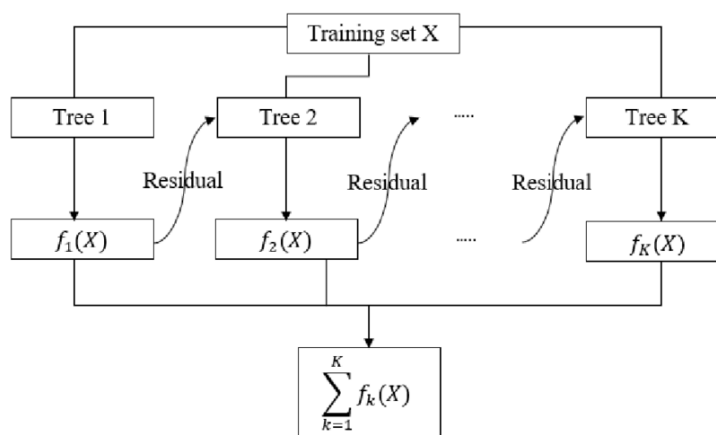
Nepaisant šių privalumų, neuroninių tinklų taikymas nekilnojamojo turto kainoms prognozuoti susiduria su iššūkiais, tokiais kaip didelio duomenų kiekio apdorojimas, modelių interpretacijos sudėtingumas bei potencialus persimokymas. Todėl norint taikyti neuroninius tinklus, reikia korektiškai parinkti modelio architektūrą ir atlikti duomenų paruošimą. Visi šie veiksniai leidžia suprasti, kad neuroninių tinklų metodas turi didelį potencialą NT kainos prognozavimui, bet reikalauja didelių laiko sąnaudų, norint sukurti optimalų modelį.

#### **1.4. Gradientinio stiprinimo metodai nekilnojamojo turto kainoms prognozuoti**

Gradientinio stiprinimo metodai yra vienas iš pažangiausių mašininio mokymosi algoritmu, kurie iteratyviai kuria modelius, siekdami minimizuoti prognozavimo klaidas ir tikslinti rezultatus, naudodami gradiento principais pagrįstas metodologijas. Šie metodai yra efektyvūs dirbant su didelės apimties duomenų rinkiniais, kuriuose ryšiai tarp kintamųjų yra netiesiniai ir sunkiai atskleidžiami tradiciniais statistiniais modeliais.

Pagrindinis gradientinio stiprinimo algoritmo privalumas yra jų gebėjimas kurti tikslus prognozavimo modelius, derinant silpnesnių prognozių rezultatus ir iteratyviai gerinant prognozių kokybę. Toks metodų veikimo principas leidžia sumažinti duomenų triukšmo įtaką galutiniams prognozavimo rezultatams [21].

Gradientinio stiprinimo algoritmai, tokie kaip *XGBoost*, *LightGBM* ir *CatBoost*, buvo plačiai taikomi nekilnojamojo turto kainų prognozavimo uždaviniams spręsti dėl aukšto jų prognozių tikslumo ir stabilumo įvairaus pobūdžio duomenims. Algoritmas *XGBoost* yra vienas populiariausių gradientinio stiprinimo metodų, pasižymintis dideliu tikslumu ir gebėjimu valdyti savo hiperparametrus, tai leido tiksliai suderinti modelį konkrečiam duomenų rinkiniui [22]. Gradientinio stiprinimo modelio architektūra abstrakcija pateikiama (žr. 3 pav.).



3 pav. *XGBoost* algoritmo veikimo principas [20]


Atlikti tyrimai patvirtina, kad gradientinio stiprinimo algoritmai gerai prognozuoja nekilnojamojo turto kainas. Viename iš tyrimų *XGBoost* metodas buvo taikytas prognozuojant būsto kainas ir pademonstravo aukštą tikslumo lygį bei patikimumą. Metodas aiškiai pralenkė klasikinius modelius, kaip tiesinę regresiją ir sprendimo medžius [13]. Kitame tyrime buvo atliktas palyginimas tarp trijų pagrindinių gradientinio stiprinimo algoritmų: *XGBoost*, *LightGBM* ir *CatBoost*. Šio tyrimo rezultatai parodė, kad *LightGBM* buvo efektyviausias metodas, kai reikėjo greitai ir tiksliai apdoroti didelius duomenų rinkinius, o *CatBoost* pasiekė geriausius rezultatus dirbant su kategoriniais kintamaisiais, dėl savo specifinių optimizavimo strategijų [23].

Viena iš reikšmingiausių problemų yra metodo jautrumas hiperparametrų parinkimui. Norint pasiekti aukštą tikslumą ir išvengti persimokymo, būtina atlikti hiperparametrų optimizaciją, naudojant tokias technikas kaip kryžminę validaciją ar automatizuotus hiperparametrų paieškos metodus [24].

### 1.5. Konvoliuciniai neuroniniai tinklai nekilnojamojo turto kainoms prognozuoti

Konvoliuciniai neuroniniai tinklai yra dirbtinių neuroninių tinklų tipas, plačiai naudojamas vaizdo atpažinimo ir klasifikavimo uždaviniams spręsti. Šis metodas pasižymi gebėjimu išgauti reikšmingus vaizdų požymius ir panaudoti juos prognozavimui ar klasifikavimui. Nekilnojamojo turto kainų prognozavime CNN leidžia analizuoti vaizdinę informaciją.

Pagrindinis CNN pranašumas – gebėjimas automatiškai išgauti požymius iš vaizdų, todėl modeliai gali geriau įvertinti NT vizualinius aspektus. Tokie tinklai gali būti apmokyti naudojant didelius vaizdinių duomenų rinkinius, leidžiančius identifikuoti svarbiausias savybes [17, 26]. Klasikinė CNN architektūra pateikta (žr. 4 pav.).



4 pav. Klasikinė konvoliucinio neuroninio tinklo struktūra [25]

Ankstesniuose tyrimuose pastebėta, kad CNN tinklai sėkmingai pritaikomi NT kainų prognozavimui. Modeliai analizuodavo būsto interjero ir eksterjero vaizdus kartu su tekstiniais aprašymais, taip siekdami pagerinti kainų prognozių tikslumą [17]. Rezultatai parodė, kad integruojant CNN išgautus vizualinius požymius su tekstiniais duomenimis prognozių tikslumas buvo aukštesnis negu tradicinių modelių, naudojančių tik struktūrinius ar tekstinius duomenis [17].

Kitame tyrime pasiūlytas CNN pagrįstas modelis, įtraukiantis įvairią lokacijos informaciją NT nuomos kainų prognozavimui [26]. Tyrimo metu buvo pastebėta, kad išgauti požymiai padėjo įvertinti kaimynystėje esančių objektų poveikį nuomos kainoms, taip pasiekiant geresnę prognozių tikslumą negu taikant standartinius statistinius metodus [26].

Atliktuose tyrimuose CNN tinklai taikyti NT vaizdinių duomenų klasifikavimui ir būsto kainų prognozavimui, analizuojant vizualines charakteristikas, tokias kaip pastato būklė, interjero dizainas ir eksterjero estetika [27]. Modeliai buvo apmokyti naudojant NT skelbimų platformų vaizdus, o gauti vizualiniai požymiai žymiai pagerino kainų prognozavimo tikslumą, palyginti su modeliais, naudojančiais tik struktūrinius požymius [27].

Tačiau, nepaisant šių privalumų, CNN taikymas NT kainų prognozavimui turi tam tikrų trūkumų. Modelių interpretacijos sudėtingumas dažnai apsunkina paaiškinimą, o tinklų mokymui reikalingas didelis kiekis kokybiškų ir tinkamai sužymėtų vaizdinių duomenų.

## 1.6. Gylio metrikų įvertinimas iš vieno vaizdo kadro

Gylio metrikų įvertinimas iš vieno kadro yra viena iš plačiausiai nagrinėjamų užduočių kompiuterinės regos srityje. Ši technologija leidžia išgauti erdvinę informaciją ir atkurti trimatę aplinkos struktūrą iš vieno RGB vaizdo. Vieno kadro gylio įvertinimas turi potencialą įvairiose srityse, įskaitant robotiką, autonominius automobilius ir virtualią realybę, nes leidžia atkurti realaus pasaulio erdvės suvokimą nenaudojant brangių *LiDAR* jutiklių ar *stereo* kamerų [28, 29].

Šiuolaikiniai neuroniniai tinklai, tokie kaip *DenseDepth*, *MiDaS* ir *DepthAnything*, dažniausiai paremti sudėtingomis CNN architektūromis ir dideliais, iš anksto apmokytais duomenų rinkiniais. Šie modeliai demonstruoja aukštą bendrąją tikslumą įvairiose aplinkose. Puikus pavyzdys yra *MiDaS* modelis, kuris, išmokytas naudojant įvairius duomenų rinkinius, geba tiksliai prognozuoti gylį tiek vidaus, tiek lauko sąlygomis [30].

Vis dėlto, vieno kadro gylio įvertinimas turi tam tikrų apribojimų. Vienas pagrindinių yra gylio informacijos dviprasmiškumas ir priklausomybė nuo mokymo duomenų rinkinio, kas riboja taikymą nežinomose ar retai sutinkamose aplinkose. Kita problema yra jautrumas apšvietimo pokyčiams bei specifinėms scenos kompozicijoms, kurios gali sukelti gylio vertinimo klaidų [30, 31].

## **1.7. Modelių asamblėjos pritaikymas nekilnojamojo turto kainoms prognozuoti**

Modelių asamblėja yra mašininio mokymosi metodas, leidžiantis sujungti kelis skirtingus prognozavimo modelius. Tokios sistemos dažnai išnaudoja įvairius duomenų tipus ir skirtingų modelių privalumus, kad būtų gautas kuo tikslesnis galutinis rezultatas.

Nekilnojamojo turto (NT) kainų prognozavimas yra sudėtinga užduotis, nes kainai įtaką daro daugybė veiksnių, tokių kaip būsto dydis, vieta, interjero ir eksterjero savybės bei infrastruktūra. Šiai problemai spręsti pasiūlyti metodai, paremti modelių asamblėjomis, kurie apjungia įvairius duomenų šaltinius, tokius kaip tekstiniai aprašymai, būsto charakteristikos ir vizualiniai duomenys, siekiant tikslesnės kainos prognozės [17, 32, 33, 34].

Viename tyrime pasiūlyta sistema, kuri apjungia NT objektų tekstinius, erdvinis, būsto charakteristikų bei vizualinius duomenis. Tyrimo autoriai teigia, kad multimodaliniai modeliai, naudojantys tiek tekstinius aprašymus, tiek nuotraukas, gali ženkliai padidinti NT kainų prognozavimo tikslumą, palyginti su metodais, kurie remiasi tik tradiciniais struktūriniais duomenimis [17]. Integruotas požiūris leidžia geriau atskleisti paslėptus ryšius tarp būsto savybių ir rinkos kainos.

Kitame tyrime buvo analizuojami modeliai, apjungiantys NT interjero, eksterjero ir palydovinius vaizdus, kurių požymiai buvo išgauti naudojant konvoliucinius neuroninius tinklus. Šių tinklų išgauti požymiai buvo integruojami su tradicinėmis NT charakteristikomis galutiniam kainos įvertinimui. Gautais eksperimentų rezultatais įrodyta, kad taikant šią metodologiją galima reikšmingai sumažinti prognozavimo klaidas [32].

Dar viename darbe nagrinėta asamblėja, kai NT kainos prognozuojamos derinant struktūrinius duomenis su nuotraukomis, iš kurių nustatomas būsto brangumo lygis. Rezultatai patvirtino, kad vizualinių savybių integravimas padeda tiksliau įvertinti būsto rinkos vertę, ypač atsižvelgiant į estetiką ir vizualinę būklę [33].

Modelių asamblėjos metodai, apjungiantys skirtingų tipų duomenis, leidžia reikšmingai pagerinti NT kainų prognozavimo tikslumą. Pagrindiniai šių metodų privalumai yra gebėjimas optimaliai išnaudoti įvairaus pobūdžio informaciją. Vis dėlto, tokių sistemų įgyvendinimas dažnai reikalauja didelių skaičiavimo resursų bei sudėtingo hiperparametrų parinkimo kiekvienam sistemoje esančiam modeliui suderinti [34].

## **1.8. Problemos formulavimas**

Atlikus literatūros analizę matyti, kad pastaruoju metu yra susidomėjimas dirbtinio intelekto metodų taikymu NT kainų prognozavimui. Literatūroje pateikiama tyrimų, patvirtinančių nestruktūruotų duomenų svarbą NT vertinime. Buvo pastebėta, kad MM modeliai bei modelių asamblėjos dažnai taikomi šioje srityje siekiant apjungti įvairius duomenų tipus ir taip pagerinti prognozių tikslumą. Vis dėlto trūksta darbų, kurie detaliai analizuotų, kokie konkretūs požymiai, išgauti iš nuotraukų, gali padidinti regresinių modelių tikslumą.

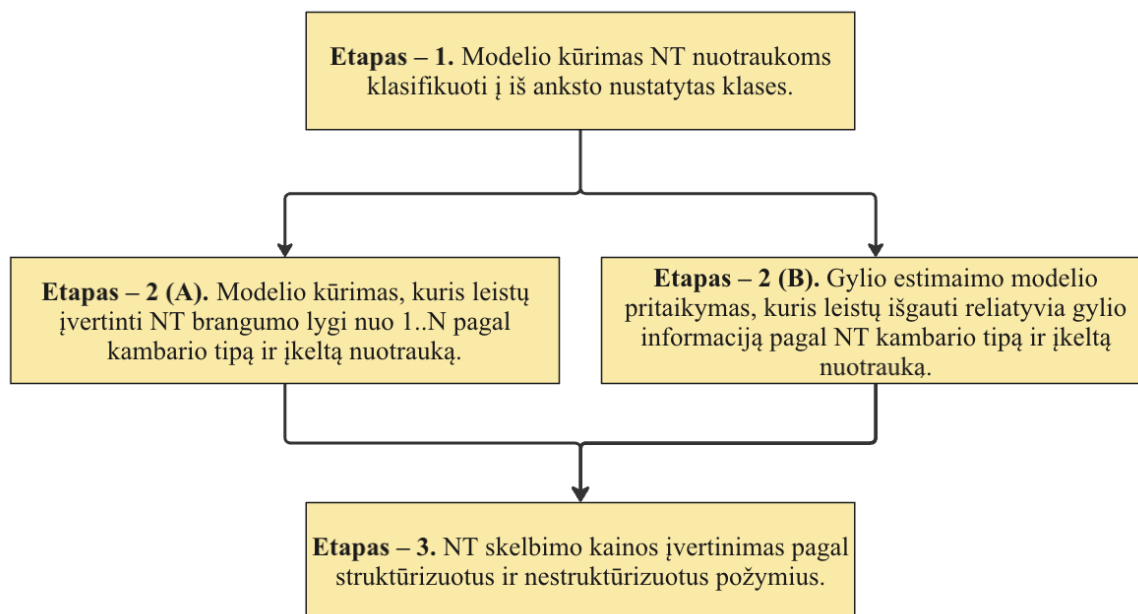
Todėl šiame darbe bus siekiama sukurti ir išanalizuoti skirtingus NT kainų prognozavimo modelius, naudojančius tiek struktūrinius, tiek vaizdinius duomenis. Bus palygintas modelių tikslumas, kai naudojami tik struktūriniai arba tik vaizdiniai požymiai, ir apibrėžta metodologija, leidžianti apjungti abu duomenų tipus į integruotą NT kainų prognozavimo sistemą bei atlikti NT skelbimų kainų prognozes.

## 2. Nekilnojamojo turto kainų prognozavimo proceso metodologija

Šiame skyriuje aprašoma nekilnojamojo turto kainų prognozavimo sistemos metodologija. Jame apžvelgiami pagrindiniai modelių asamblėjos principai, leidžiantys sujungti skirtingus modelius į vientisą prognozavimo sistemą ir atlikti NT kainų prognozę.

### 2.1. NT kainų prognozavimo etapai

Nekilnojamojo turto kainų prognozavimo procesą sudaro keli svarbūs etapai, kurių kiekvienas prisideda prie bendros NT kainų prognozavimo sistemos. Etapai ir jų tarpusavio sąveika yra pavaizduoti (žr. 5 pav.).



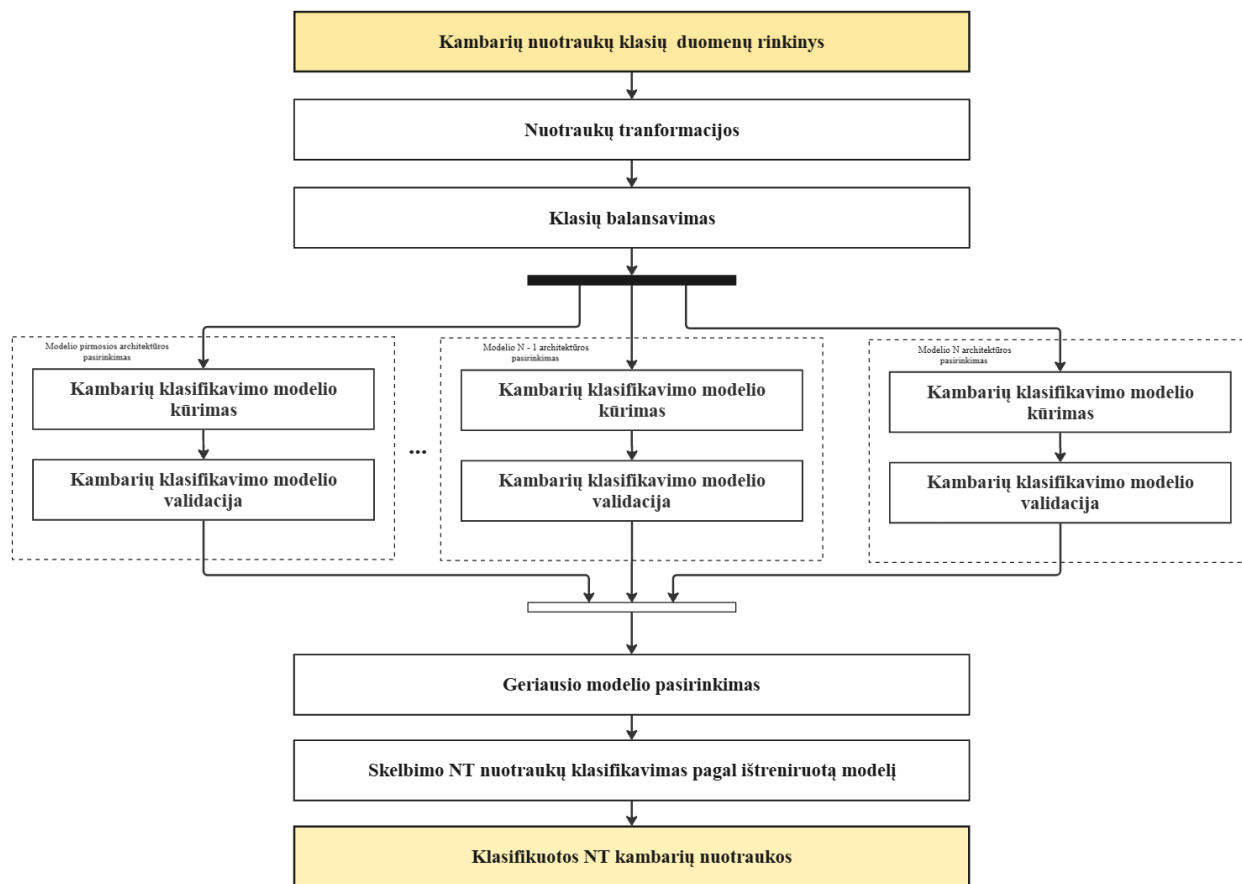
5 pav. Pagrindiniai metodologijos etapai

Šie etapai apima įvairius duomenų apdorojimo žingsnius – nuo vaizdinės informacijos interpretavimo iki prognozavimo pagal išgautus požymius. Pradiniai tyrimo etapai apima nuotraukų apdorojimą, kurio metu nustatomi NT patalpų tipai, vizualiniai brangumo lygiai ir gylio charakteristikos. Galiausiai visi surinkti požymiai naudojami NT kainų prognozei atlikti. Apibendrinant, kiekvienas etapas įgyvendina tam tikrą metodologijos komponentą, siekiant sukurti NT kainų prognozavimo modelių asamblėją.

#### 2.1.1. Pirmasis etapas – kambarių tipų klasifikacija

Vienas iš sistemos komponentų yra modelis, leidžiantis klasifikuoti NT nuotraukas į iš anksto nustatytas klases. Šio etapo metu bus nagrinėjamos įvairios CNN architektūros ir įvertintas jų

gebėjimas klasifikuoti NT kambarių nuotraukas pagal atitinkamus tipus. Apibendrintas procesas pavaizduotas (žr. **6 pav.**).



**6 pav.** Kambarių tipų klasifikavimo procesas

Kambarių klasifikavimo procesas prasideda nuo duomenų rinkinio sudarymo. Šį rinkinį sudarys įvairių kambarių tipų nuotraukos, pažymėtos atitinkamomis klasėmis. Toliau atliekamos būtinos nuotraukų transformacijos, tokios kaip dydžio keitimas, normalizacija ir duomenų augmentacija. Šios transformacijos užtikrins, kad modelis būtų atsparesnis skirtingoms apšvietimo sąlygoms bei nuotraukų kampams. Siekiant išvengti vienos ar kelių klasių dominavimo, bus įvertintas klasių balansavimas.

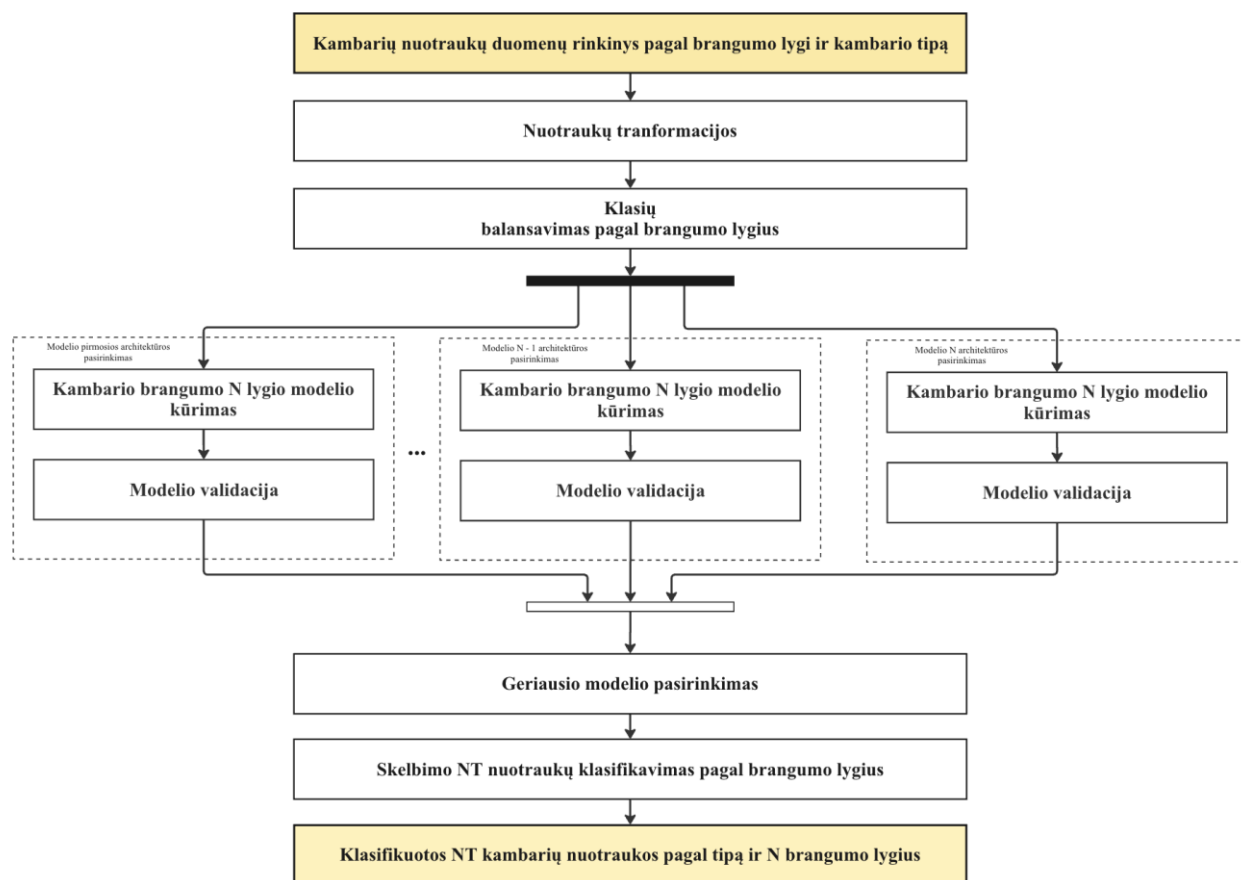
Toliau vyks modelių kūrimas ir testavimas, taikant skirtingas architektūras bei hiperparametrų rinkinius. Šio etapo metu modeliai bus apmokyti ir palyginti, pasirenkant geriausią pagal apibrėžtas kokybės metrikas.

Geriausią rezultatą pasiekęs klasifikavimo modelis taps pagrindiniu tolesniame NT nuotraukų apdorojimo etape. Jis bus naudojamas NT skelbimų nuotraukų klasifikacijai, kurios metu kiekviena nuotrauka bus priskirta konkrečiam kambario tipui. Nuotraukos, kurių klasifikacijos patikimumas bus nepakankamas (mažesnis nei 80 %), bus pašalintos. Galutinis šio etapo rezultatas yra klasifikuotos NT kambarių nuotraukos.

### 2.1.2. Antrasis etapas – kambarių brangumo lygių klasifikacija

Antras sistemos komponentas yra kambarių brangumo lygių klasifikavimo modelis, leidžiantis nustatyti vizualinį brangumo lygį pagal NT kambario nuotraukas ir kambario tipą. Šio etapo tikslas yra apmokyti modelį atpažinti ir klasifikuoti kambarių brangumo lygius nuo 1 iki N, remiantis

vizualine informacija. Vizualiniai brangumo lygiai suteiks daugiau konteksto apie NT kambario būklę, reikalingą kainų prognozei atlikti. Apibendrintas procesas pavaizduotas (žr. **7 pav.**).



**7 pav.** Kambarių brangumo lygių klasifikavimo procesas

Procesas prasideda nuo duomenų rinkinio, kuriame yra kambarių nuotraukos, suklasifikuotos pagal brangumo lygius – nuo pigiausių iki prabangiausių. Nuotraukos taip pat klasifikuojamos pagal kambario tipus, nes brangumo lygiai bus vertinami atsižvelgiant į konkretų kambario tipą. Vizualiniai brangumo požymiai apima interjero detales, baldus bei kitus dekoratyvinius elementus.

Tolimesniame etape atliekamos nuotraukų transformacijos, užtikrinančios duomenų kokybę ir modelio atsparumą skirtingoms sąlygoms. Šios transformacijos padeda modeliui geriau išmokti brangumo požymius net esant nevienodoms nuotraukų kokybės sąlygoms, kurios dažnai būdingos realiems NT skelbimams.

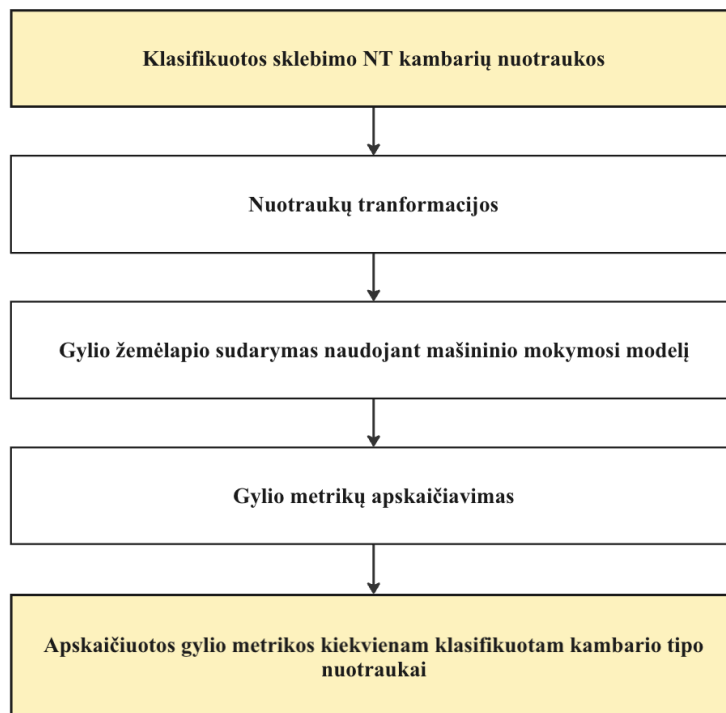
Kitoje proceso dalyje vykdomas modelių kūrimas ir validacija. Šiame žingsnyje išbandomos įvairios konvoliucinių neuroninių tinklų architektūros bei eksperimentuojama su skirtingais hiperparametrais. Kadangi brangumo lygiai pasižymi progresyvumu, bus atliekamas klasifikavimo metodų palyginimas naudojant regresijos principus. Modeliai apmokomi subalansuotais duomenimis ir atitinkamai įvertinami naudojant tikslumo bei patikimumo metrikas.

Siekiant sumažinti atsitiktines klaidas ir užtikrinti rezultatų stabilumą, kiekvienas brangumo lygių klasifikavimo modelis apmokomas ir tikrinamas kelis kartus, naudojant skirtingas architektūras. Galutiniame žingsnyje atrenkamas geriausiai pasirodęs modelis pagal nustatytas kokybės metrikas.

Pasirinktas geriausias modelis taikomas NT skelbimų nuotraukų klasifikavimui, nustatant kambarių vizualinius brangumo lygius bei jų klasifikavimo patikimumą. Galutinis šio etapo rezultatas yra NT kambarių nuotraukos, klasifikuotos pagal kambario tipą ir nustatytus brangumo lygius.

### 2.1.3. Trečiasis etapas – kambarių gylio įvertinimas

Šiame etape taikomas gylio prognozavimo modelis, kuris leis iš NT skelbimų nuotraukų išgauti reliatyvią kambarių gylio informaciją. Gylio požymiai svarbūs, nes suteikia papildomo NT erdvės konteksto, padedančio geriau suprasti kambarių matmenis ir struktūrines savybes. Bendras kambario erdvės išgavimo proceso vaizdas pavaizduotas (žr. **8 pav.**).



**8 pav.** Kambarių gylio įvertinimo procesas

Gylio nustatymo proceso pradžioje bus naudojamas jau apmokytas gylio įvertinimo modelis, kuris priims kambario RGB nuotrauką ir sugeneruos atitinkamą gylio žemėlapi. Šiame tyrime naudojami viešai prieinami, iš anksto apmokyti modeliai, todėl šiame etape nebus sudaromas naujas duomenų rinkinys ar papildomai apmokomas modelis.

Iš sugeneruoto gylio žemėlapi bus išgaunami šie struktūriniai požymiai: kambario plotis, aukštis, gylis, tūris, įvairūs proporciniai santykiai ir statistiniai gylio rodikliai:

- Kambario plotis yra kambario matmenys išilgai kambario;
- Kambario aukštis yra kambario matmenys nuo grindų iki lubų;
- Kambario gylis yra kambario matmenys nuo priekio iki galo;
- Kambario tūris yra visa kambario erdvė, apskaičiuota pagal plotį, aukštį ir gylį;
- Pločio ir aukščio santykis yra proporcinis santykis tarp kambario pločio ir aukščio;
- Pločio ir gylio santykis yra proporcinis santykis tarp kambario pločio ir gylio;
- Aukščio ir gylio santykis yra proporcinis santykis tarp kambario aukščio ir gylio;
- Tankis yra gylio taškų žemėlapi tankis;
- Vidutinis gylis yra vidutinė gylio reikšmė pagal gylio žemėlapi;
- Gylio mediana yra vidurinė gylio reikšmė arba antrasis kvartilis;
- Gylio standartinis nuokrypis yra matmuo, pasakantis, kaip gylio reikšmės skiriasi nuo vidurkio;

- Minimalus gylis yra mažiausia gylio reikšmė gylio žemėlapyje;
- Maksimalus gylis yra didžiausia gylio reikšmė gylio žemėlapyje.

Kadangi šiame tyrime neturime tikslių NT objektų matmenų, visi išgaunami požymiai bus reliatyvūs. Absoliučių matmenų interpretavimas metrais būtų galimas tik turint papildomos informacijos apie kiekvienos nuotraukos mastelį. Nepaisant šio apribojimo, reliatyvūs gylio požymiai bus naudingi kuriant erdvinis kontekstinius modelius. Gylio modelio sukurtas 3D erdvės vaizdas pavaizduotas (žr. **9 pav.**).



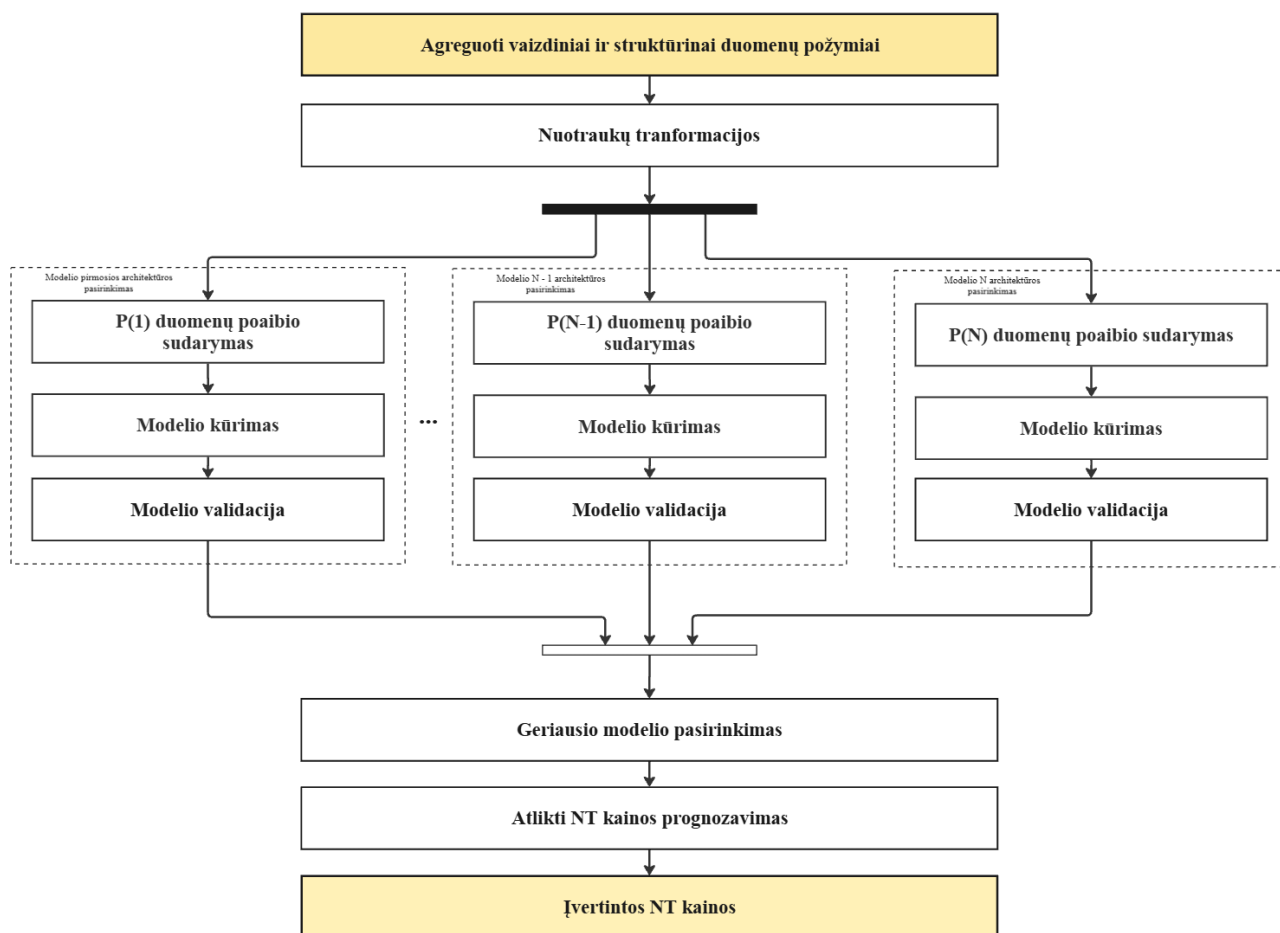
**9 pav.** Sudaryto gylio modelio koncepcija 3D erdvėje [35]

Šiame etape išgauti gylio požymiai bus naudojami kaip įvestis galutiniame modelių asamblėjos etape, kuriame kartu su kitais vizualiniais ir skelbimo struktūriniais požymiais bus atliekama NT kainos prognozė. Kadangi sudarytų gylio žemėlapių negalime patikrinti su tikrais NT skelbimų matmenimis, požymių tinkamumas bus vertinamas remiantis jų reikšmingumu atliekant NT kainų prognozavimą.

#### **2.1.4. Ketvirtasis etapas – NT kainų įvertinimas pagal struktūrinius ir vaizdinius požymius**

Šiame etape atliekamas nekilnojamojo turto kainų įvertinimas derinant struktūrinius ir vaizdinius požymius, išgautus ankstesniuose tyrimo etapuose. Struktūriniai duomenys apima informaciją, tokią kaip NT objekto dydis, kambarių skaičius, žemės plotas bei statybos metai. Vaizdiniai duomenys apima anksčiau išgautus vizualinius požymius – kambarių brangumo lygius ir reliatyvią gylio informaciją iš NT kambarių nuotraukų.

Proceso pradžioje atliekamas visų turimų duomenų sujungimas ir standartizavimas. Šios transformacijos leis naudoti tiek struktūrinius, tiek vaizdinius požymius viename modelyje. Apibendrintas šio etapo procesas pavaizduotas (žr. **10 pav.**).



**10 pav.** NT kainų įvertinimo procesas pagal struktūrinius ir vaizdinius požymius

Proceso metu formuojami atskiri duomenų poaibiai (požymių grupės). Modelių apmokymas bus atliekamas su įvairiomis požymių kombinacijomis, siekiant nustatyti, kurios požymių grupės daro didžiausią įtaką NT kainoms. Sudaromos šios požymių grupės:

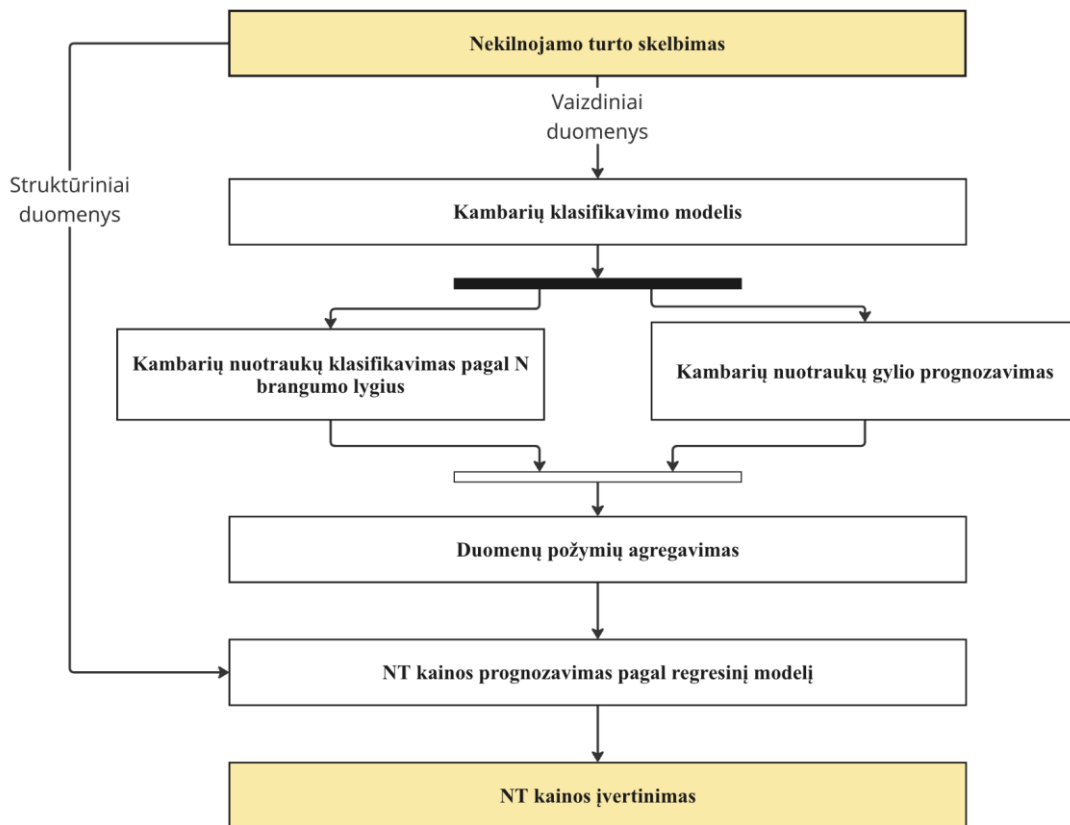
- Vien tik struktūrinių duomenų požymiai;
- Vien tik vizualinių duomenų požymiai;
- Kombinuoti struktūriniai ir vizualiniai požymiai.

Pagrindinės modelių vertinimo metrikos bus vidutinė absoliuti paklaida (angl. „*Mean Absolute Error*“), kvadratinės šaknies vidutinė paklaida (angl. „*Root Mean Squared Error*“) ir vidutinė absoliutinė procentinė paklaida (angl. „*Mean Absolute Percentage Error*“). Šios metrikos padės nustatyti, kokios požymių kombinacijos leidžia tiksliausiai prognozuoti NT kainas.

Galiausiai pasirenkamas geriausiai pasirodęs modelis, pasižymintis mažiausiomis prognozavimo klaidomis tarp prognozuotų ir realių kainų. Remiantis šio etapo rezultatais, bus galima nustatyti, kaip struktūriniai ir vaizdiniai požymiai padeda prognozuoti NT kainas bei kurios požymių kombinacijos leidžia pasiekti didžiausią prognozavimo tikslumą. Galutinis šio etapo rezultatas yra NT kainų prognozavimo modelis, įvertinantis tiek vizualinę informaciją, tiek struktūrinius duomenis.

## 2.2. Modelių asamblėja

Modelių asamblėja sujungia skirtingų tipų modelius, gautus ankstesniuose etapuose, į vieną bendrą sistemą, galinčią apdoroti įvairius NT skelbimus ir atlikti kainos prognozę. Modelių asamblėjos architektūra pavaizduota (žr. **11 pav.**).



**11 pav.** Modelių asamblėja

Modelių asamblėja sukurta taip, kad galėtų priimti įvairių tipų duomenis apie nekilnojamąjį turtą. Šie duomenys apima struktūrinius požymius, tokius kaip objekto dydis, kambarių skaičius ar statybos metai. Taip pat sistema apdoroja vaizdinius duomenis, tokius kaip NT objektų nuotraukos. Naudojant CNN, nuotraukos analizuojamos ir iš jų išgaunami reikšmingi požymiai, galintys turėti įtakos objekto vertei.

Modelių asamblėja atlieka prognozes remdamasi tiek struktūriniais, tiek vaizdiniais duomenimis. Apibendrintas procesas ir komponentai:

1. Nekilnojamojo turto skelbimas – procesas prasideda nuo NT skelbimo, kuris pateikia tiek struktūrinę, tiek vaizdinę informaciją apie NT objektą;
2. Kambarių klasifikavimo modelis – vaizdinė NT informacija perduodama kambarių klasifikavimo modeliui, kuris atlieka klasifikaciją pagal iš anksto nustatytus kambarių tipus. Šis etapas užtikrina, kad iš nuotraukų rinkinio būtų atrenkamos tinkamiausios nuotraukos, reikalingos kambarių brangumo vertinimui;
3. Brangumo įvertinimo modelis – šis modelis nustato kambario brangumo lygį nuo 1 iki N, kur 1 žymi pigiausią, o N prabangiausią NT lygį. Modelis įvertina brangumo lygį pagal kambario tipą ir vizualinę informaciją;
4. Gylio prognozavimo modelis – naudojamas gylio prognozavimo modelis, leidžiantis iš kiekvienos kambario nuotraukos išgauti reliatyvią geometrinę informaciją;
5. Duomenų agregavimas – šiame etape po kambarių klasifikavimo ir brangumo vertinimo apjungiamos gautos metrikos. Modulis taip pat apdoroja geometrinius požymius, išgautus iš gylio žemėlapių, ir paverčia juos standartizuotais požymiais. Tokiu būdu sukuriamas vieningas NT objekto profilis, apimantis kambarių tipus, jų brangumo lygius bei geometrinę informaciją;

6. Regresinis modelis – struktūriniai duomenys kartu su suagreguotais brangumo lygiais ir gylio metrikomis naudojami NT kainos įvertinimo modeliui sukurti. Modelio tikslumas didinamas naudojant tiek struktūrinius, tiek iš vaizdinių duomenų išgautus požymius;
7. Kainos įvertinimas – galutinis rezultatas yra tikslus NT kainos įvertinimas, apimantis reikšmingiausius faktorius iš skirtingų duomenų šaltinių. Kartu pateikiami svarbiausi kintamieji, darantys didžiausią įtaką NT kainai.

Apibendrinant, modelių asamblėja leidžia integruoti įvairius duomenų tipus ir modelius į vieną sistemą, užtikrindama tikslesnę NT kainų prognozę. Procesas apima kambarių klasifikavimą, brangumo ir gylio įvertinimą, duomenų agregavimą bei galutinės NT kainos apskaičiavimą regresiniu modeliu.

### 2.3. Modelių vertinimo metrikos

Tyrime modelių tikslumui įvertinti bus naudojamos regresijos ir klasifikavimo uždaviniams dažnai taikomos metrikos. Kiekvieno modelio metrikos bus apskaičiuojamos testavimo duomenų aibėje. Mokymo ir testavimo duomenų rinkiniai bus sudaryti iš bendro duomenų rinkinio, laikantis santykio 8:2 (80 % – mokymo, 20 % – testavimo).

Vidutinė absoliutinė paklaida (*angl. „Mean Absolute Error“*) matuoja vidutinį absoliutų skirtumą tarp tikrosios reikšmės  $y$  ir modelio prognozės  $\hat{y}$ . Kuo ši reikšmė mažesnė, tuo tiksliau modelis prognozuoja realius duomenis.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

Vidutinė kvadratinė paklaida (*angl. „Mean Squared Error“*) rodo vidutinį paklaidų kvadratų dydį. Didesnės prognozavimo paklaidos šioje metrikoje turi didesnę įtaką vertinimui.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

Kvadratinės šaknies vidutinė paklaida (*angl. „Root Mean Squared Error“*) yra MSE kvadratinė šaknis. Ši metrika naudojama siekiant paprasčiau interpretuoti MSE reikšmę. Šios metrikos formulė pateikiama toliau:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

Vidutinė absoliutinė procentinė paklaida (*angl. „Mean Absolute Percentage Error“*) nusako vidutinį prognozės absoliučios paklaidos procentą, palygintą su tikrosiomis reikšmėmis. Kuo MAPE reikšmė mažesnė, tuo modelis tikslesnis.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100\% \quad (4)$$

Determinacijos koeficientas (*angl. „Coefficient of determination“*) nusako, kokią duomenų dispersijos dalį paaiškina modelis. Kuo šis rodiklis artimesnis 1, tuo geriau modelis atspindi duomenų kitimą. Jei šis rodiklis artimas 0, modelis praktiškai nepaaiškina duomenų dispersijos.

$$R^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

Patikimumas (*angl.* „Accuracy“) yra skirtas parodyti, kokią duomenų dalį modelis sugeba klasifikuoti teisingai. Jei norėtume įvertinti tikslumą binarinei modelio klasifikacijai.

$$ACC = \frac{TP + TN}{FP + FN + TP + TN} \quad (6)$$

Tikslumas (*angl.* „Precision“) apibūdina, kiek iš visų modelio pateiktų vienos klasės spėjimų yra teisingi. Ši metrika yra svarbi norint įvertinti, kaip klasifikavimo modelis prognozuoja kiekvieną klasę. Jei norėtume įvertinti vienos klasės tikslumą binarinei modelio klasifikacijai.

$$PREC = \frac{TP}{TP + FP} \quad (7)$$

Atšaukimas (*angl.* „Recall“) parodo, kokią dalį visų realių klasės atvejų modelis sugebėjo aptikti. Aukštas atšaukimas reiškia, kad modelis praleidžia mažai tikrų teigiamų atvejų, kurie klaidingai pažymimi kaip neigiami. Ši metrika ypač aktuali tais atvejais, kai klaidingai neaptikti atvejai yra itin reikšmingi.

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

F1 rodiklis (*angl.* „F1-score“) yra tikslumo ir atšaukimo harmoninis vidurkis, atsižvelgiantis į abi metrikas. Šis rodiklis naudingas, kai duomenų klasės nėra subalansuotos arba kai vienodai svarbūs tikslumas ir atšaukimas.

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (9)$$

Apibendrinant, tyrime modelių kokybei įvertinti bus taikomos kelios, skirtingus tikslumo aspektus apimančios metrikos. Šis vertinimo planas leidžia tinkamai įvertinti tiek klasifikavimo, tiek regresinius modelius. Geriausiai pasirodę modeliai pagal atitinkamas metrikas bus įtraukti į galutinę modelių asamblėją.

#### 2.4. Modelių asamblėjos klaidų kaskada

Viena iš problemų, su kuriomis susiduria modelių asamblėjomis pagrįstos sistemos, yra prognozavimo klaidų kaskada [36]. Žemiau pateikta klaidų kaskados formulė parodo, kaip tarpinės asamblėjos klaidos gali paveikti galutinę kainos prognozę. Galima teigti, kad galutinė kaina  $\hat{y}$  apskaičiuojama kaip funkcija  $f$  iš struktūrinių duomenų  $x$ , kambario tipo  $\hat{c}$ , brangumo lygio  $\hat{l}$  ir gylio įvertinimo  $\hat{d}$ .

$$\hat{y} = f(x, \hat{c}, \hat{l}, \hat{d}) \quad (10)$$

Jeigu  $\Delta\hat{c}$ ,  $\Delta\hat{l}$ ,  $\Delta\hat{d}$  apibūdina atitinkamai kambario tipo klasifikavimo, brangumo lygio ir gylio įvertinimo klaidas, tuomet bendrą klaidą  $\Delta\hat{y}$  galime išreikšti pirmos eilės *Teilorio* eilutės aproksimacija [37].

$$\Delta\hat{y} \approx \frac{\partial f}{\partial \hat{c}} \Delta\hat{c} + \frac{\partial f}{\partial \hat{l}} \Delta\hat{l} + \frac{\partial f}{\partial \hat{d}} \Delta\hat{d} \quad (11)$$

Išraiška leidžia suprasti, kad nedidelės klaidos ankstesniuose žingsniuose (kambario tipo klasifikacijoje, brangumo lygio nustatyme ar gylio prognozavime) prisideda atitinkamai prie galutinės kainos prognozės paklaidos [37, 38]. Todėl svarbu pastebėti, kad bent vieno komponento padarytos klaidos sukelia klaidingas įvestis tolimesniems modeliams.

## **2.5. Metodologijos apibendrinimas**

Tyrimo metu buvo sukurta NT kainos prognozavimo modelių asamblėjos architektūra ir apibrėžtas metodologijos planas. Sistemoje numatyta NT kainą prognozuoti naudojant tiek struktūrinius, tiek vaizdinius duomenis. Pagrindiniai modelių asamblėjos komponentai yra:

1. Kambarių tipų klasifikavimas, brangumo lygių nustatymas ir gylio prognozavimas – sistemą sudarys įvairūs CNN modeliai, skirti analizuoti NT nuotraukas. Iš šių nuotraukų bus išgaunami reikšmingi struktūriniai ir vizualiniai požymiai;
2. Klaidų minimizavimas ir validacija – apibrėžtos kokybės vertinimo metrikos, leidžiančios įvertinti kiekvieno modelio tikslumą ir pritaikomumą. Modelių kokybės vertinimas bei prognozavimo klaidų mažinimas yra itin svarbūs, nes tarpinės modelių paklaidos gali lemti klaidų kaskadą visoje modelių sistemoje;
3. Modelių asamblėja – ją sudarys tarpusavyje integruoti modeliai. Ši architektūra leis sujungti iš struktūrinių ir vaizdinių duomenų išgautus požymius į vientisą regresinį modelį. Galiausiai visi požymiai bus naudojami regresijoje, leidžiančioje tiksliai prognozuoti NT kainą.

Metodologija remiasi NT skelbimų duomenimis, surinktais iš viešai prieinamų šaltinių, tokių kaip nekilnojamojo turto skelbimų platformos. Svarbu paminėti, kad tyrimas turi tam tikrų apribojimų, nes modelių tikslumas priklauso nuo turimų duomenų kokybės ir gylio įvertinimo reliatyvumo, nes nėra galimybės tiksliai patvirtinti iš nuotraukų išgautų erdvinių požymių absoliučių matmenų. Nepaisant šių apribojimų, taikant pasiūlytą metodologiją tikimasi pagerinti NT kainų prognozavimo tikslumą.

### 3. Nekilnojamojo turto kainų prognozavimo eksperimentai


#### 3.1. Kambarių tipo klasifikavimas

Pirmasis modelių asamblėjos žingsnis yra NT skelbimų nuotraukų klasifikavimas pagal kambarių tipus. Šiam tikslui bus apmokomas konvoliucinis neuroninis tinklas, kuris priims vaizdinę kambario informaciją ir atliks kambario tipo klasifikaciją. Kadangi asamblėjoje numatytas vienas CNN modelis, bus išbandomos skirtingos CNN architektūros ir atrinktas tiksliausias modelis.

Klasifikavimui naudojamas *REI* duomenų rinkinys, sudarytas iš 4980 kambarių nuotraukų [39], suskirstytų į šešias klases pagal kambario tipą:

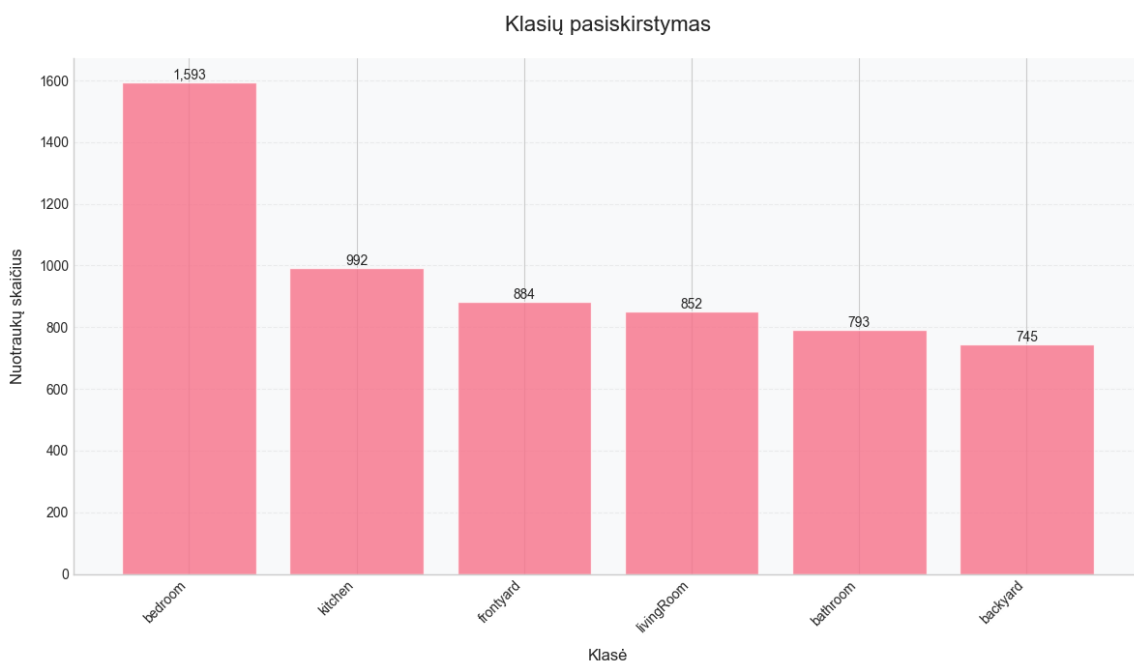
- Kiemas;
- Vonios kambarys;
- Miegamasis;
- Priekinis kiemas;
- Virtuvė;
- Svetainė.

Skirtingi kambarių tipai bei nuotraukų skaičius pavaizduoti (žr. **12 pav.**).



**12 pav.** *REI* duomenų rinkinio klasės

Duomenų pasiskirstymo diagrama yra pateikta (žr. **13 pav.**). Iš pateiktų duomenų pasiskirstymo aiškiai galime pastebėti, kad duomenys yra nesubalansuoti. Iš diagramos aiškiai matyti, kad duomenų rinkinys yra nesubalansuotas, nes daugiausia nuotraukų yra miegamojo klasėje, o mažiausiai kiemo klasėje.



**13 pav.** REI duomenų rinkinio klasių pasiskirstymo diagrama

Modeliai, apmokyti naudojant nesubalansuotus duomenis, gali ženkliai sumažinti klasifikavimo tikslumą. Siekiant išspręsti klasių disbalanso problemą, kiekvienai klasei buvo priskirti atitinkami svoriai, leidžiantys mokymo metu duomenis paskirstyti tolygiai. Vaizdai papildomai buvo modifikuoti naudojant *AutoAugmentPolicy* metodą su *ImageNet* strategija bei atitinkamai normalizuoti ir standartizuoti.

Tyrime išbandytos kelios CNN modelių architektūros su iš anksto apmokytais svoriais. Modeliai pasirinkti pagal jų populiarumą bei pritaikomumą įvairioms kompiuterinės regos užduotims spręsti. Nagrinėtos modelių architektūros pateiktos nuosekliai:

- *Vision Transformers (ViT)*;
- *EfficientNet*;
- *ResNet*;
- *Visual Geometry Group (VGG)*;
- *MobileNet*;
- *Data-Efficient Image Transformers (DeiT)*;
- *ConvNeXt*.

Modelių apmokymo metu naudotas *AdamW* optimizatorius, keičiant mokymosi žingsnį intervale [0.00001; 0.0001] su 0.00001 žingsnio pokyčiu, bei maksimalų epochų skaičių. Kiekvienos architektūros eksperimento rezultatai pateikti (žr. **1 lentelė**).

**1 lentelė.** Kambarių tipų klasifikavimo eksperimentų rezultatai

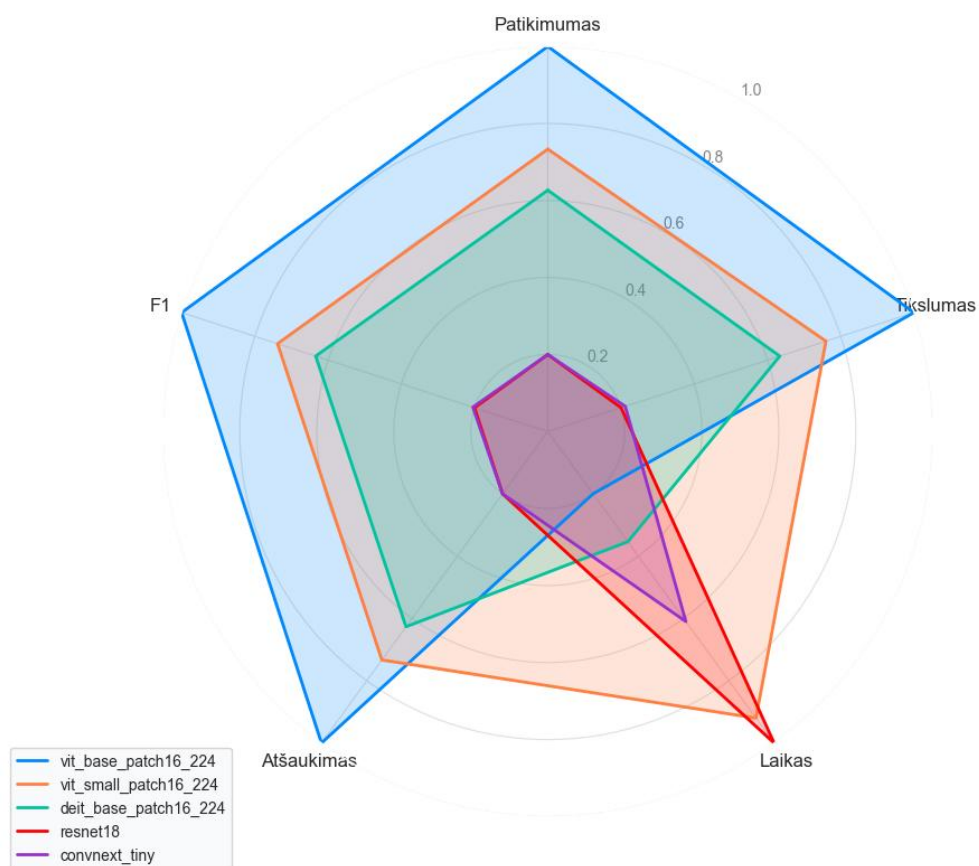
Modelis	Architektūra	Žingsnis	Mak. epochų sk.	Prec, %	Acc, %	F1-score, %	Recall, %	Laikas, s
Vision Transformers (ViT)	vit_base_patch16_224	0.00001	20	97.9831	97.9522	97.9425	97.9522	403.274644
Vision Transformers (ViT)	vit_small_patch16_224	0.00002	20	97.5937	97.5256	97.5250	97.5256	258.040020
Vision Transformers (ViT)	vit_tiny_patch16_224	0.00005	15	95.9391	95.9044	95.8960	95.9044	450.034445

ConvNeXt	convnext_tiny	0.00001	10	96.7065	96.6724	96.6753	96.6724	320.556078
ResNet	resnet18	0.0001	10	96.6879	96.6724	96.6678	96.6724	241.862838
ResNet	resnet34	0.00005	10	96.4847	96.4164	96.4203	96.4164	263.951318
EfficientNet	efficientnet_b0	0.0001	10	96.5456	96.5017	96.5087	96.5017	318.744470
EfficientNet	efficientnet_b1	0.00005	10	95.8070	95.7338	95.7478	95.7338	387.733206
EfficientNet	efficientnet_b2	0.00001	15	96.0950	96.0750	96.0703	96.0750	350.155964
EfficientNet	efficientnet_b3	0.00002	10	96.3300	96.3822	96.4049	96.3822	373.048019
EfficientNetV2	efficientnetv2_rw_s	0.00005	10	95.6484	95.8409	95.6613	95.6484	436.764745
EfficientNetV2	efficientnetv2_rw_t	0.0001	10	96.2214	96.1604	96.1441	96.1604	425.974074
MobileNet	mobilenetv2_100	0.0001	10	95.5254	95.3924	95.3865	95.39249	271.033431
MobileNet	mobilenetv3_small_100	0.0001	10	95.24943	94.8805	94.9022	94.8805	274.018651
MobileNet	mobilenetv3_large_100	0.00005	15	95.64846	95.6486	95.6477	95.6484	281.812174
VGG	vgg11	0.0001	10	95.4909	95.3925	95.4150	95.3925	325.282069
DeiT	deit_tiny_patch16_224	0.00001	10	96.2457	96.2727	96.2561	96.2457	300.696223
DeiT	deit_base_patch16_224	0.00001	15	97.3897	97.3549	97.3591	97.3549	372.267064

Remiantis eksperimentų rezultatais matyti, kad aukščiausią klasifikavimo tikslumą 97.98 % pasiekė *ViT* modelis naudojant *vit\_base\_patch16\_224* architektūrą. Šis modelis taip pat parodė geriausius rezultatus pagal visas naudojamas kokybės metrikas. Gautas tikslumas yra vienas aukščiausių palyginus su kitų tyrimų rezultatais, kuriuose buvo naudojamas *REI* duomenų rinkinys [33, 34].

Rezultatai leidžia teigti, kad CNN modeliai efektyviai klasifikuoja kambarių tipus pagal nuotraukas, kadangi vidutinis tikslumas viršija 95%. Aukštas klasifikavimo tikslumas dažnai pasiekiamas jau per pirmąsias penkias mokymo epochas, o tolesnis mokymas reikšmingų patobulinimų neparodo. Tai leidžia daryti prielaidą, kad modeliai greitai išmoksta pagrindinius požymius, reikalingus tiksliam klasifikavimui, o ilgesnis mokymas gali lemti persimokymą.

Greitas modelių konvergavimas mokymo metu taip pat rodo aukštą duomenų rinkinio kokybę, aiškiai išreikštus bei lengvai atpažįstamus požymius. Nors *DeiT*, *ResNet* ir *ConvNeXt* modeliai taip pat pasiekė aukštus rezultatus tačiau *ViT* modelis juos lenkia tikslumu. Siekiant aiškiau palyginti geriausius modelius pagal skirtingas metrikas buvo naudota modifikuota *min-max* normalizacija. Geriausių modelių palyginimas pateiktas (žr. **14 pav.**).




**14 pav.** Geriausių kambarių tipų klasifikavimo modelių palyginimo diagrama

Apibendrinant, tyrimo etapas yra sėkmingai įgyvendintas pagal apibrėžtą metodologiją. Apmokytas ViT modelis *vit\_base\_patch16\_224* leidžia klasifikuoti NT nuotraukas į kambarių tipus su 97.98 % tikslumu. Šis modelis bus naudojamas modelių asamblėjoje ir kituose tyrimo etapuose, nustatant kambario tipą pagal vizualinę informaciją.

### 3.2. Kambarių brangumo lygio įvertinimas

Antrasis modelių asamblėjos etapas yra NT skelbimų nuotraukų brangumo lygių nustatymas. Šio etapo metu iš anksčiau klasifikuotų kambarių nuotraukų bus nustatomas kiekvieno kambario vizualinis brangumo lygis. Brangumo lygiui įvertinti bus naudojamas CNN modelis, apmokytas duomenimis iš internetinės platformos *Houzz*. Ši platforma naudotojams pateikia interjero dekoravimo idėjas, suskirstytas į keturias brangumo kategorijas: 0 – mažo brangumo, 1 – vidutinio brangumo, 2 – didelio brangumo ir 3 – labai didelio brangumo. Brangumo lygių pavyzdžiai pateikti (žr. **15 pav.**).



**15 pav.** Svetainės brangumo lygių duomenų rinkinio pavyzdžiai

Norint apmokyti kambarių brangumo klasifikavimo CNN modelį, buvo surinkta po 1000 vaizdų kiekvienai brangumo klasei ir kiekvienam kambario tipui, iš viso sudarant 16000 nuotraukų duomenų rinkinį. Kadangi Houzz platformoje priekinio ir galinio kiemo nuotraukų atskirti negalima, šios klasės buvo sujungtos į vieną bendrą lauko klasę. Surinktas duomenų rinkinys yra subalansuotas – kiekviena klasė turi vienodą nuotraukų skaičių. Nuotraukos buvo apdorotos pagal pirmame etape aprašytą transformacijų strategiją.

Tyrime buvo išbandytos kelios CNN modelių architektūros su iš anksto apmokytais svoriais. Pasirinktos tos pačios architektūros, kurios naudotos kambarių tipo klasifikavimo etape. Modelių įvestį sudarė kambario tipas ir nuotrauka, o išvestį – brangumo lygis nuo 0 iki 3. Mokant modelius naudotas AdamW optimizatorius, keičiant mokymosi žingsnį intervale [0.0001; 0.001] su 0.0001 žingsnio pokyčiu bei maksimalų epochų skaičių. Eksperimentų rezultatai pateikti (žr. **3.2 lentelė**).


**3.2 lentelė.** Kambarių brangumo klasifikavimo eksperimentų rezultatai

Modelis	Architektūra	Žingsnis	Mak. epochų skaičius	Prec, %	Acc, %	F1-score, %	Recall, %	Laikas, s
Vision Transformers (ViT)	vit_base_patch16_224	0.0001	10	35.9750	35.5845	35.6353	35.9750	1142.75
Vision Transformers (ViT)	vit_small_patch16_224	0.0001	10	37.1674	38.7500	36.7078	38.7500	753.53
Vision Transformers (ViT)	vit_tiny_patch16_224	0.0001	10	39.2303	38.8000	37.5671	39.4500	760.79
ConvNeXt	convnext_tiny	0.0001	10	39.7408	39.4500	37.5671	39.4500	1000.84

ResNet	resnet18	0.0002	10	40.4756	39.6000	39.6385	39.6000	707.83
ResNet	resnet34	0.0002	10	40.8897	41.5750	41.1163	41.5750	813.77
EfficientNet	efficientnet_b0	0.0002	10	40.6538	40.1250	39.9966	40.1250	916.80
EfficientNet	efficientnet_b1	0.0002	10	39.0502	39.7750	39.7750	39.2400	1078.68
EfficientNet	efficientnet_b2	0.0002	10	41.0774	40.9750	38.5681	40.9750	1074.16
EfficientNet	efficientnet_b3	0.0001	10	40.1205	40.5000	40.2723	40.5000	1141.07
EfficientNetV2	efficientnetv2_rw_s	0.0001	10	39.7249	39.9750	39.3373	39.9750	1385.45
EfficientNetV2	efficientnetv2_rw_t	0.0002	10	40.3159	41.1250	40.4859	41.1250	1287.97
MobileNet	mobilenetv2_100	0.0002	10	40.0821	41.0500	38.4167	41.0500	773.62
MobileNet	mobilenetv3_small_100	0.0001	10	38.3118	39.0500	38.4256	39.0500	848.68
MobileNet	mobilenetv3_large_100	0.0002	10	40.2741	41.5250	40.1819	41.5250	797.70
VGG	vgg11	0.0001	10	37.3924	37.9000	37.0669	37.9000	1022.05
DeiT	deit_tiny_patch16_224	0.0001	10	38.3930	39.5500	38.4989	39.5500	822.94
DeiT	deit_base_patch16_224	0.0001	10	39.7289	38.9250	31.5222	38.9250	1273.49

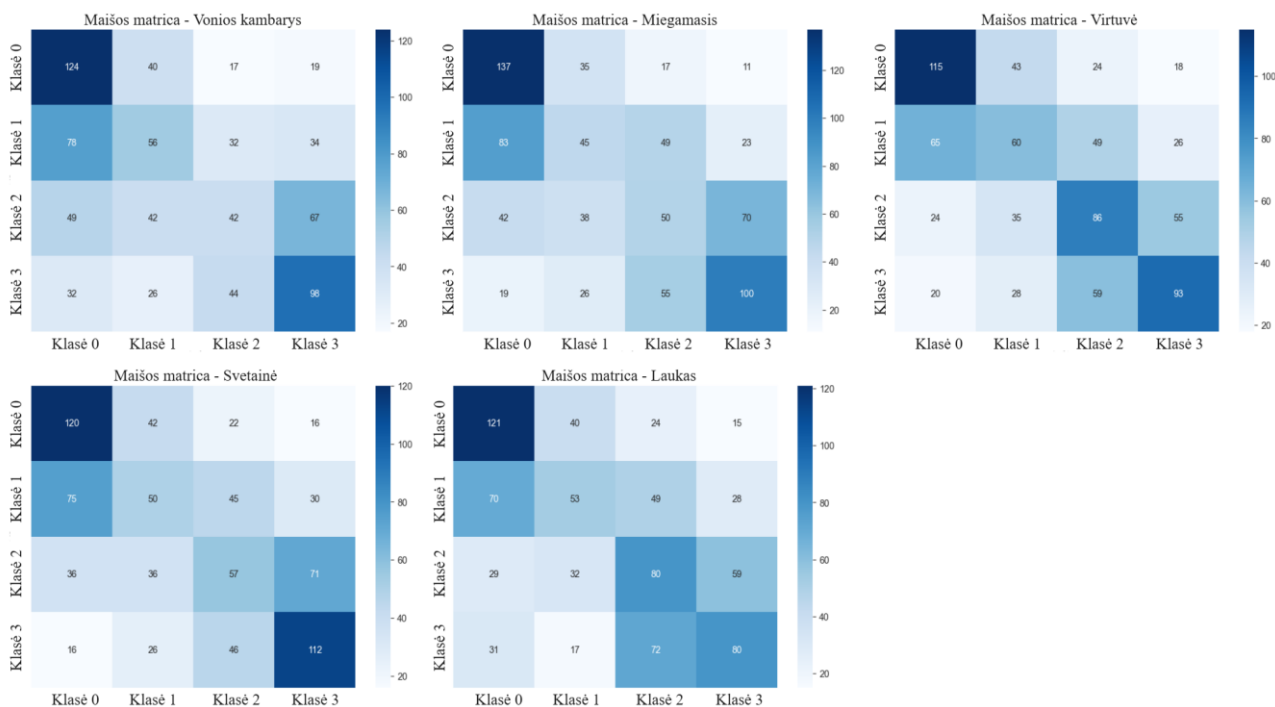
Remiantis gautais rezultatais, galima pastebėti, kad aukščiausią kambarių brangumo klasifikavimo tikslumą pasiekė CNN tipo modelis *ResNet*, naudojantis *ResNet34* architektūra. Šis modelis atliko klasifikavimą su 41.58 % tikslumu ir taip pat parodė geriausias rezultatus pagal tikslumo, F1 ir atšaukimo metrikas, nors skirtumai tarp geriausių modelių nėra labai dideli.

Iš gautų rezultatų galime pastebėti, kad modeliai, kaip *ResNet*, *ConvNeXt* ir *EfficientNet*, demonstravo geresnius rezultatus nei *ViT* architektūros modeliai. Apmokant įvairius modelius, didžiausias tikslumas buvo pasiektas per pirmąsias 10 mokymo epochų, o papildomos epochos reikšmingo rezultatų pagerėjimo nedavė. Galima teigti, kad CNN modeliai identifikuoja svarbius vizualinius požymius, pagal kuriuos galima klasifikuoti kambarių brangumo lygius. Vis dėlto dėl duomenų rinkinio sudėtingumo ir aiškių tendencijų trūkumo sukurti modeliai negali pasiekti aukšto prognozavimo tikslumo. Visų modelių tikslumas viršijo 25 %, todėl galima daryti išvadą, kad jie geba nustatyti reikšmingus požymius, tačiau dėl duomenų rinkinio neapibrėžtumo negali atlikti pakankamai tikslaus prognozavimo. Papildomi architektūros bei duomenų pakeitimai ryškaus tikslumo pagerėjimo nedavė. Geriausių modelių palyginimo normalizuoti rezultatai pateikti (žr. **16 pav.**).



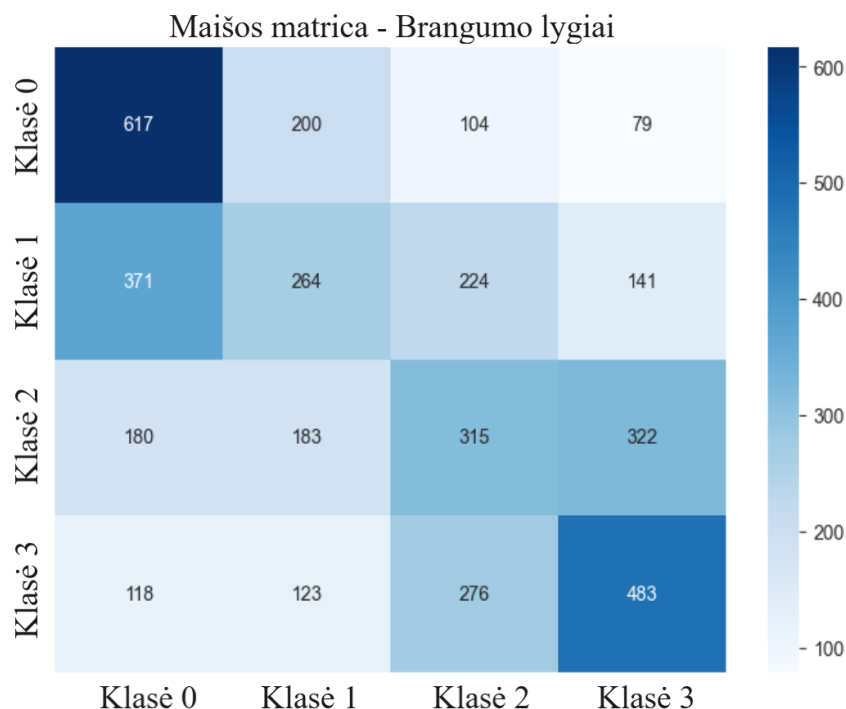
16 pav. Geriausių brangumo lygių klasifikavimo modelių palyginimo diagrama

Iš gautų rezultatų matyti, kad klasifikavimas dažnai painioja gretimas brangumo klases. Ši tendencija aiškiai matoma sumaišties matricose, kuriose dažnai supainiojamos artimiausios klasės dėl progresyvaus pasiskirstymo. Tokios tendencijos buvo galima tikėtis atsižvelgiant į subjektyvų kambarių brangumo suvokimą. Kiekvienos klasės sumaišties matrica pateikta (žr. 17 pav.).



17 pav. Kiekvieno kambario tipo sumaišties matricos reprezentuojančios brangumo lygius

Taip pat pastebėta, kad kambarių brangumo lygis pasižymi progresyviu pobūdžiu. Todėl buvo išbandytas ir regresinis klasifikavimas, tačiau jo bendras tikslumas neviršijo CNN modelių pasiektų rezultatų. Geriausio CNN modelio brangumo lygio sumaišties matrica pateikta (žr. **18 pav.**).



**18 pav.** Maišos matrica reprezentuojanti brangumo lygį

Apibendrinant galima teigti, kad šis tyrimo etapas buvo sėkmingai įgyvendintas. Apmokytas *ResNet34* modelis vidutiniu tikslumu įvertina kambarių brangumo lygį ir pateikia naudingos informacijos apie bendras brangumo tendencijas. Šis modelis bus naudojamas tolimesniuose tyrimo etapuose bei integruotas į modelių asamblėją.

### 3.3. Gylio žemėlapių kūrimas

Siekiant išgauti struktūrizuotus duomenis, tokius kaip kambarių gylio požymiai, buvo atliekamas gylio įvertinimas naudojant pavienes RGB nuotraukas. Iškelta hipotezė, kad monokuliarinis gylio įvertinimas gali suteikti pakankamai naudingos informacijos apie NT objektą. Šiai užduočiai buvo pasirinktas *Depth-Anything-V2-Metric-Indoor-Large-hf* modelis, kuris yra pritaikytas kurti kambarių gylio žemėlapiams iš vieno kadro RGB nuotraukų.

Kadangi eksperimentuose naudoti tik RGB vaizdai, o tikrieji kambarių matmenys nėra žinomi, norint vizualiai atlikti rezultatų palyginimą, gylio žemėlapiams buvo transformuojami į debesies taškų (*angl.* „*Point Cloud*“) modelius. Taškų debesies atvaizdavimas 3D erdvėje leidžia vizualiai įvertinti kambario geometriją. Šiam konvertavimui buvo naudojama standartinė projekcinė transformacija, paremta virtualios kameros vidinių parametrų matrica  $K$ .

$$K = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \quad (12)$$

$f_x, f_y$  – židinio nuotolis pikseliais apskaičiuotas iš kameros matymo kampo (FOV) pagal atitinkamą formulę.

$$f_x = f_y = \frac{\frac{w}{2}}{\tan\left(\frac{FOV}{2}\right)} \quad (13)$$

$c_x, c_y$  – vaizdo centro koordinatės pikseliais galime aprašyti naudojant nuosekliai pateikta formulė.

$$c_x = \frac{w}{2}, c_y = \frac{h}{2}; \quad (14)$$


kur  $w$  ir  $h$  yra vaizdo plotis ir aukštis pikseliais, o FOV – virtualios kameros matymo kampas laipsniais (tyrime naudotas  $70^\circ$  kampas).

Gylio žemėlapių pikselių reikšmės  $z_{ij}$  buvo transformuojamos į 3D erdvės koordinates ( $X, Y, Z$ ) naudojant atitinkamas projekcines formules.

$$X = \frac{(i - c_x) \cdot z_{ij}}{f_x}, Y = \frac{(j - c_y) \cdot z_{ij}}{f_y}, Z = z_{ij}; \quad (15)$$


kur  $(i, j)$  – pikselio koordinatės vaizdo plokštumoje, o  $z_{ij}$  – atitinkamo pikselio gylio vertė.

Taip sukonstruoti taškų debesys buvo naudojami vizualiai kambario formai ir proporcijoms įvertinti 3D erdvėje. Iš tų pačių debesų apskaičiuoti kambario matmenys, leidžiantys nustatyti papildomus geometrinius požymius, tokius kaip kambario tūris, atskirų matmenų santykiai bei statistiniai gylio rodikliai. Puikus pavyzdys yra NT skelbime pateikiama kambario nuotrauka (žr. **19 pav.**).



**19 pav.** Kambario vaizdas, pateiktas NT skelbime

Naudojant gylio įvertinimo modelį gautas prognozuojamas gylio žemėlapis pateikiamas (žr. **20 pav.**).



**20 pav.** Kambario apskaičiuotas gylio žemėlapis

Kadangi tikrieji gylio žemėlapiai ir matmenys nėra žinomi, modelio tikslumą patvirtintame tik vizualiai, analizuojant gautus taškų debesis išgautus iš gylio žemėlapio. Vizualiai vertinant pastebėta, kad kambario forma ir proporcijos atrodo logiškai ir tikroviškai. Taškų debesų vizualizacijos iš skirtingų perspektyvų pateiktos (žr. **21 pav.**).




**21 pav.** Sudarytas kambario 3D taškų debesis modelis iš skirtingų perspektyvų

Apibendrinant galima teigti, kad *Depth-Anything-V2-Metric-Indoor-Large-hf* modelis yra tinkamas atlikti gylio įvertinimą. Gautieji kambarių gylio požymiai bus naudojami galutiniame etape. Svarbu pastebėti, kad tos pačios klasės kambarių požymiai bus agreguojami apskaičiuojant jų vidurkius.

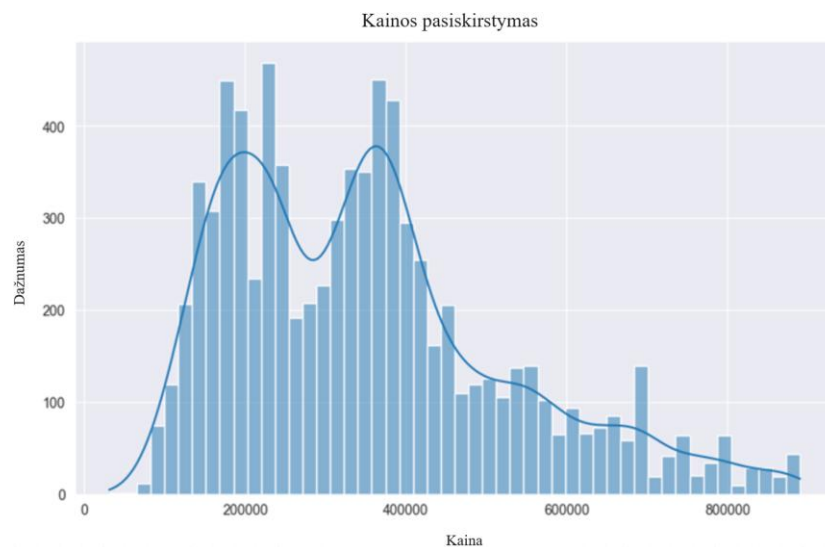
### 3.4. Prognozavimas pagal struktūrinius ir vaizdinius duomenis

Tyrime naudojamas NT duomenų rinkinys, sudarytas iš Hiustono bei aplinkinių miestų ir apylinkių NT skelbimų. Duomenys surinkti iš internetinės svetainės *Redfin*, kuri yra viena populiariausių NT skelbimų platformų JAV. Skelbimai buvo atrinkti naudojant 90 kilometrų spindulį nuo Hiustono miesto centro (platumą 29.7604, ilgumą -95.3698). Dabartinį duomenų rinkinį sudaro 8200 NT skelbimų. Surinktų skelbimų šilumos žemėlapis pateiktas (žr. **22 pav.**).



22 pav. NT skelbimų šilumos žemėlapis

Prieš atliekant NT kainų prognozavimą pagal turimus skelbimus, būtina įvertinti duomenų kokybę bei kainų pasiskirstymo tendencijas. Siekiant užtikrinti, kad duomenų rinkinyje nebūtų ekstremalių reikšmių, buvo taikoma tarpkvartilinio intervalo (IQR) metodika. Ji leidžia identifikuoti ir pašalinti ekstremalias reikšmes. NT kainų pasiskirstymas po išskirčių pašalinimo pateiktas (žr. 23 pav.).



23 pav. Nekilnojamojo turto kainų pasiskirstymo histograma


Siekiant detaliau įvertinti NT kainų pasiskirstymą, buvo apskaičiuoti pagrindiniai statistiniai rodikliai. Šie rodikliai pateikti (žr. 3.3 lentelė).

3.3 lentelė. NT kainų statistiniai rodikliai

Vidurkis	Mediana	Standartinis nuokrypis	Asimetrija	Smailumas	Tarpkvartilinis diapazonas (IQR)	Diapazonas	1-asis kvartilis (Q1)	3-iasis kvartilis	Minimumas	Maksimumas
351 159.58	334 000.00	173 804.173	0.8574	0.2678	225 000.00	859 001.00	210 000.00	435 000.00	30 999	890 000

Jei būsimų modelių prielaidos reikalaus normalumo bus atliekamos atitinkamos kainų reikšmių transformacijos. Atliekant požymių tarpusavio koreliacijos analizę, galime pastebėti, kad yra nemažai požymių, kurie tarpusavyje yra stipriai koreliuoti. Požymių koreliacijos problema bus sprendžiama,

tik jei pasirinkto modelio prielaida reikalaus identifikuoti tiesinės arba netiesinės duomenų ryšius. Požymių koreliacijos matrica pateikiama (žr. **24 pav.**).



**24 pav.** Struktūrinių ir vaizdinės informacijos požymių koreliacijos matrica

NT kainų prognozavimas buvo testuotas naudojant skirtingas požymių kombinacijas, įskaitant struktūrinius NT duomenis (H), kambarių brangumo lygius (L) bei gylio metrikas (D), išgautas iš kambarių nuotraukų. Iš viso buvo išbandytos 7 skirtingos požymių kombinacijos leidžiančios įvertinti kiekvienos požymių grupės įtaką prognozės tikslumui. Požymių grupės yra pateiktos (žr. **27 pav.** ir **28 pav.**).

Pradiniams eksperimentams buvo pasirinktas *XGBoost* modelis dėl savo aukšto tikslumo atliekant panašių problemų prognozavimus. Naudojant *XGBoost* algoritmą nėra būtina užtikrinti duomenų rinkinio normalumo prielaidos ar atlikti papildomos tiesinių ir netiesinių kintamųjų koreliacijos analizės. Tai ypač naudinga NT kainų prognozavimui, kur duomenys dažnai neatitinka statistinių prielaidų.

Modelio vertinimo funkcija buvo pasirinkta pagal šaknies vidurkio kvadratinės paklaidos RMSE rodiklį. Norint nustatyti optimalius modelio hiperparametrus, buvo taikyta automatinė hiperparametrų optimizacija naudojant *Optuna* biblioteką ir atlikti 250 eksperimentiniai bandymai kiekvienai požymių grupei. Optimizacijos procese buvo tiriami šie *XGBoost* modelio hiperparametrai:

- Maksimalus medžio gylis nuo 4 iki 15;
- Mokymosi greitis nuo 0.001 iki 1.0;
- Medžių skaičius nuo 50 iki 500;
- Minimalus mazgo svoris nuo 1 iki 10;

- Reguliavimo parametras nuo 0 iki 5.

Optimizacijos tikslinė funkcija naudojo kryžminės validacijos metodą, kuris buvo paremtas *KFold* validacija. Skaičiavimams buvo naudojama GPU akceleracija. Taip pat, duomenys buvo atitinkamai apdoroti:

- Skaitinių požymių standartizavimas ir normalizavimas;
- Kategorinių požymių kodavimas;
- Trūkstatų reikšmių užpildymas mediana;
- Sukuriami trūkstatų reikšmių indikatoriai.

Šis metodologinis apibrėžimas leidžia nustatyti modelio hiperparametrus, kurie turėtų būti artimi optimaliems. Galutiniai optimizuoto *XGBoost* modelio rezultatai pateikti (žr. **3.4 lentelė**).

**3.4 lentelė.** Modelio rezultatų apžvalga

Tipas	Maksimalus medžio gylis	Mokymosi žingsnis	Medžių skaičius	Minimalus mazgo svoris	Gamma	MSE	MAE	RMSE	MAPE, %	R <sup>2</sup>
H+L+D	7	0.109332	420	9	3.115481	1 538 797 365.3077	16 278.5455	39 227.5078	4.32	0.9497
H	6	0.179653	365	1	2.431171	1 310 016 138.1839	12 873.5987	36 194.1451	3.48	0.9572
L	9	0.011668	479	1	1.197059	22 917 935 774.3743	110 841.7217	151 386.7094	39.32	0.2507
D	9	0.059661	486	9	3.632038	10 996 129 728.9917	56 544.3563	104 862.4324	18.03	0.6405
D+L	10	0.061943	465	9	4.213464	10 734 166 420.3648	55 840.7772	103 605.8223	17.89	0.6491
H+D	7	0.077634	485	3	4.888440	150 988 799.3713	16 002.1464	39 382.5951	4.25	0.9493
H+L	6	0.125174	490	2	3.683442	133 2267 551.5610	14 215.7399	36 500.2404	3.86	0.9564

Remiantis *XGBoost* modelio rezultatais galima pastebėti, kad geriausią NT kainų prognozavimo tikslumą pasiekė tie modeliai, kuriuose buvo naudojami struktūriniai NT skelbimų požymiai. Didžiausias dispersijos paaiškinamumas  $R^2 = 0.9572$  ir mažiausia vidutinė absoliutinė procentinė paklaida  $MAPE = 3.48\%$  yra gaunama naudojant tik struktūrinę informaciją (H). Taip pat pakankamai geri rezultatai gaunami derinant struktūrinius duomenis (H) su papildomais požymiais, tokiais kaip kambarių brangumo lygiai (L) bei gylio metrikos (D).

Tuo tarpu modeliai, naudojantys tik kambarių brangumo lygių (L) arba gylio (D) informaciją, demonstravo ženkliai prastesnius rezultatus, ką pagrindžia didelės prognozavimo klaidos. Modelis su brangumo lygiais (L) turėjo didžiausią vidutinę absoliučią procentinę paklaidą  $MAPE = 39.32\%$  ir mažiausią dispersijos paaiškinamumą  $R^2 = 0.2507$ . Šie rezultatai leidžia suprasti, kad vien tik vaizdiniai požymiai be struktūrinių duomenų negali užtikrinti aukšto NT kainų prognozavimo tikslumo.

Svarbu paminėti, kad nors šiame tyrime vizualinė informacija pati savaime ženkliai nepagerino NT kainos prognozavimo tikslumo, naudojant tik gylio informaciją (D) buvo pasiektas pakankamai aukštas dispersijos paaiškinamumas  $R^2 = 0.6405$  ir sąlyginai gera vidutinė absoliuti procentinė paklaida  $MAPE = 18.03\%$ . Derinant gylio informaciją su kambarių brangumo lygiais (D + L), dispersijos paaiškinamumas padidėjo iki  $R^2 = 0.6491$ , o vidutinė absoliuti procentinė paklaida sumažėjo iki  $MAPE = 17.89\%$ . Tai leidžia daryti išvadą, kad gylio metrikos iš tiesų suteikia reikšmingos informacijos apie NT objektą.

Atliekant pirmąjį eksperimentą pastebėta, kad papildoma vizualinė informacija, kaip brangumo lygiai ar gylio metrikos, šiuo konkrečiu atveju nepadėjo padidinti bendrojo NT kainos prognozavimo tikslumo. Geriausias rezultatas buvo pasiektas naudojant tik struktūrinius duomenis (H). Viena galimų tokio rezultato priežasčių yra, kad didelis papildomų požymių kiekis gali apsunkinti optimalių sprendimų medžių sudarymą. Taip pat vaizdinė informacija gali persidengti arba dubliuoti struktūriniuose duomenyse jau esančias tendencijas. Taigi galima daryti prielaidą, kad struktūrinių duomenų rinkinyje jau yra labai stipriai su NT kainomis koreliuojančių požymių.

Remiantis gautais rezultatais, galima teigti, kad aukšti modelių rodikliai, naudojant struktūrinius duomenis, patvirtina stiprią šių duomenų koreliaciją su NT kainomis. Atlikus detalesnę duomenų analizę, nustatyta, kad didelę koreliaciją lemia NT skelbimų vietos informacija. Turint NT objektų geografines koordinates, gali pasitaikyti situacijų, kai kaimyniniai objektai patenka tiek į treniravimo, tiek į testavimo duomenų rinkinius, kas gali lemti dirbtinai aukštą modelio tikslumą.


Papildomai pastebėta, kad surinktame duomenų rinkinyje yra nemažai nekokybiškų NT skelbimų, kurie turi daug trūkstančių požymių. Norint objektyviai įvertinti vaizdinės informacijos įtaką NT kainų prognozavimui, todėl reikėtų atrinkti tik tuos NT skelbimus, kurie turi visų kambarių klasių nuotraukas ir kokybišką vaizdinę informaciją.

Pašalinus NT objektų koordinates ir pasilikus tik labai aukštos kokybės NT skelbimus, gautas naujas duomenų rinkinys yra sudarytas iš 1616 skelbimų. Aukštos kokybės skelbimai yra NT objektai, kurie turėjo kiekvieno kambario tipo nuotraukas. Siekdami įvertinti kainų pasiskirstymą, galime apskaičiuoti pagrindinius statistinius rodiklius. Šie rodikliai pateikiami (žr. **3.5 lentelė**).

**3.5 lentelė.** NT kainų statistiniai rodikliai

Vidurkis	Mediana	Standartinis nuokrypis	Asimetrija	Smailumas	Tarpkvartilinis diapazonas (IQR)	Diapazonas	1-asis kvartilis (Q1)	3-iasis kvartilis	Minimumas	Maksimumas
386 399	359 000	185 996.93	0.6670	-0.3082	269 922.50	787 000	230 000	499 922.50	103 000	890 000

Naujas duomenų skirstinys vizualiai primena pradinį kainų pasiskirstymą. Svarbu pastebėti, kad kainų diapazonas išliko pakankamai platus ir nėra vienos ryškios kainų koncentracijos. Todėl galima teigti, kad naujasis duomenų rinkinys yra tinkamas NT kainų prognozavimui. Naujojo duomenų skirstinio vizualizacija pateikta (žr. **25 pav.**).



**25 pav.** Nekilnojamojo turto kokybiškų duomenų kainos pasiskirstymo histograma

Buvo pakartotinai atlikti eksperimentai kiekvienai požymių grupei, kad būtų galima įvertinti, kaip mažesnis, bet kokybiškesnis duomenų kiekis bei pašalintos vietos koordinatės veikia kainų prognozavimo tikslumą. Tiriama hiperparametrų intervalai parinkti tokie patys kaip pradiniam eksperimente. Nauji *XGBoost* modelio rezultatai pateikti (žr. **3.6 lentelė**).

**3.6 lentelė.** Modelio rezultatų apžvalga pašalinus NT objektų koordinates kokybiškiems skelbimams

Tipas	Maksimalus medžio gylis	Mokymosi žingsnis	Medžių skaičius	Minimalus mazgo svoris	Gamma	MSE	MAE	RMSE	MAPE, %	R <sup>2</sup>
H+L+D	8	0.036533	443	10	3.255835	3 684 354 028.7126	26 246.6967	60 698.8800	5.67	0.8970
H	3	0.385496	321	5	2.554810	3 132 097 713.0958	23 518.4938	55 965.1473	5.40	0.9124
L	10	0.018841	151	3	3.938829	22 383 567 956.1132	105 465.6798	149 611.3898	29.94	0.3743

D	5	0.098744	463	7	3.852109	9 825 998 917.6661	45 296.0243	99 126.1768	10.11	0.7253
D+L	4	0.053617	462	8	2.603149	9 809 925 200.1823	52 427.4827	99 045.0665	12.80	0.7258
H+D	4	0.037825	492	5	3.45412	3 547 945 900.0873	29 954.6629	59 564.6363	7.07	0.9008
H+L	4	0.090993	405	8	1.68385	3 322 206 297.5579	30 023.1932	57 638.5834	7.18	0.9071

Iš gautų rezultatų matyti, kad modelis, paremtas vien struktūriniais požymiais (H), išlieka geriausias nes dispersijos paaiškinamumo koeficientas siekia  $R^2 = 0.9124$ , o vidutinė absoliutinė procentinė paklaida  $MAPE = 5.40\%$  patvirtina aukštą prognozavimo tikslumą. Į struktūrinius duomenis įtraukus papildomus vizualinius požymius, rezultatai šiek tiek suprastėja, tačiau požymių kombinacijos (H+L) ir (H+D) vis tiek išlaiko pakankamai gerus rodiklius  $R^2 = 0.9071$  ir  $R^2 = 0.9008$  bei  $MAPE = 7\%$ .

Naudojant tik kambarių brangumo lygius (L) rezultatai šiek tiek pagerėjo, palyginti su pradiniu duomenų rinkiniu, tačiau vis dar išlieka ženkliai prastesni už struktūrinių duomenų modelį  $MAPE = 29.94\%$  ir  $R^2 = 0.3743$ . Modelis, paremtas vien gylio metrikomis (D), pasiekė vidutinius rezultatus  $MAPE = 10.11\%$  ir  $R^2 = 0.7253$  parodydamas, kad gylio informacija suteikia naudingos informacijos.

Kadangi iki šiol nebuvo aiškiai matyti vaizdinių požymių įtakos bendram modelio tikslumui, tolesniame tyrimo etape visiškai pašalintos vietos koordinatės ir NT objekto miesto informacija. Eksperimento tikslas yra patikrinti, ar sumažinus kontekstinių požymių kiekį vizualiniai bruožai gali reikšmingiau pagerinti kainos prognozę. Galutiniai rezultatai pateikti (žr. **3.7 lentelė**).

**3.7 lentelė.** Modelio rezultatų apžvalga pašalinus NT objektų vietovės informaciją kokybiškiems skelbimams

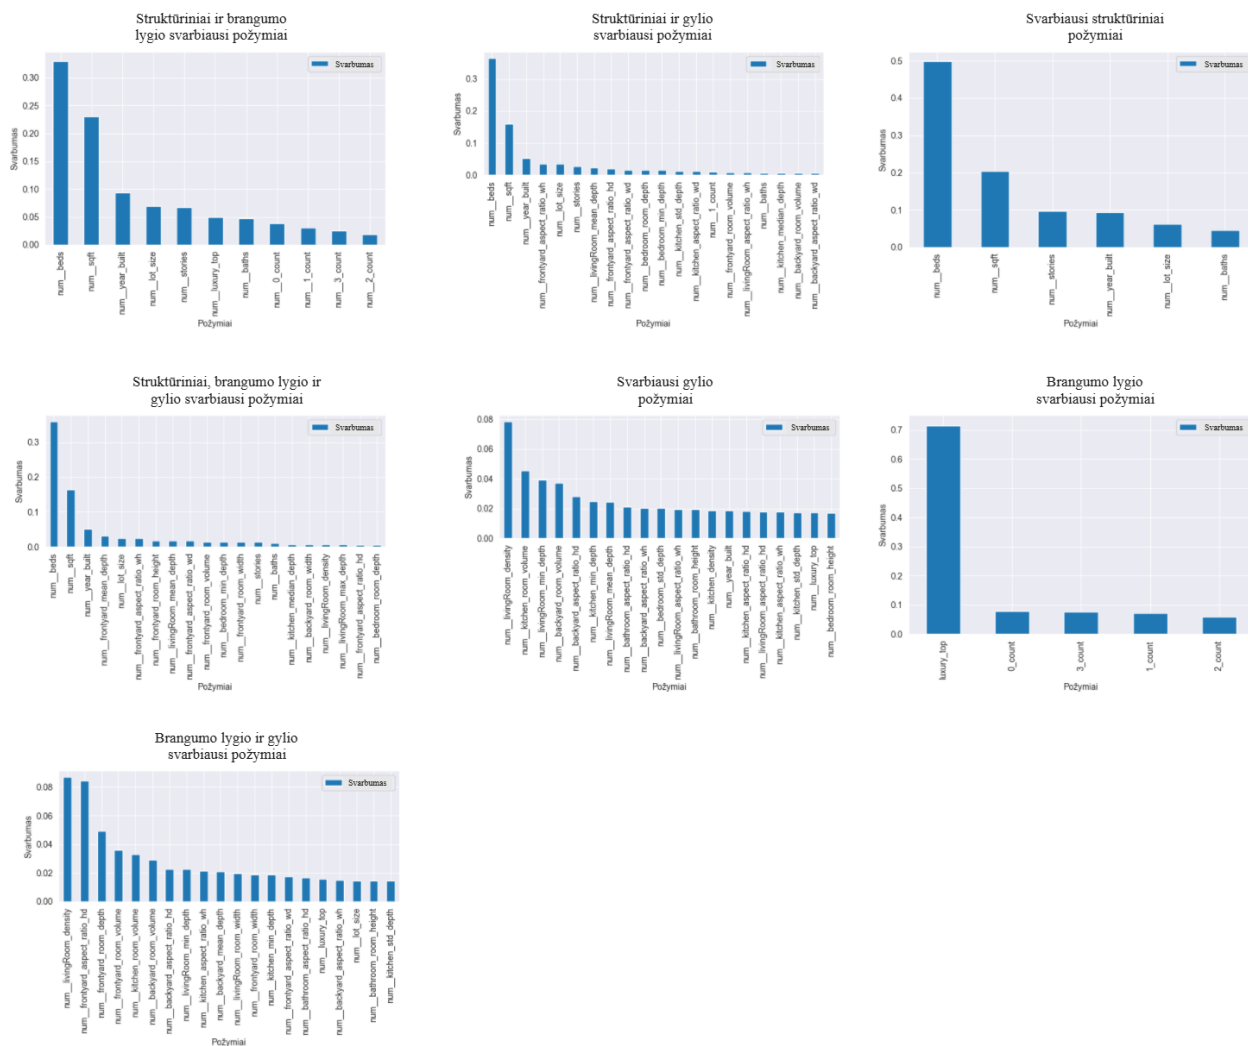
Tipas	Maksimalus medžio gylis	Mokymosi žingsnis	Medžių skaičius	Minimalus mazgo svoris	Gamma	MSE	MAE	RMSE	MAPE, %	R <sup>2</sup>
H+L+D	9	0.218029	129	9	1.952785	4 853 281 038.6982	29 786.7407	69 665.4939	6.78	0.8643
H	8	0.1422754	216	8	2.314704	5 552 626 575.4748	29 651.1372	74 515.9485	6.65	0.8448
H+D	8	0.049454	465	7	2.822179	5 246 118 138.7933	31 163.2758	72 430.0914	6.88	0.8534
H+L	5	0.170400	370	2	2.633368	4 638 898 383.1612	28 763.5472	68 109.4588	6.74	0.8703

Iš gautų rezultatų galime matyti, kad struktūrinių duomenų ir kambarių brangumo lygių derinys (H + L) suteikė geriausią tikslumą, nes dispersijos paaiškinamumo koeficientas siekia  $R^2 = 0.8703$ , o vidutinė absoliutinė procentinė paklaida  $MAPE = 6.74\%$ . Tai rodo, kad pašalinus vietovės požymius brangumo lygiai tampa reikšmingi.

Galime pastebėti, kad modelis, kuriame naudoti visi požymiai (H + L + D) pasiekė irgi pakankamai gerus rezultatus, nes gaunamas dispersijos paaiškinamumo koeficientas  $R^2 = 0.8643$ , o vidutinė absoliutinė procentinė paklaida  $MAPE = 6.78\%$ .

Modelis su vien struktūriniais požymiais (H) nusileido aukščiau minėtoms požymių grupėms, nes gautas dispersijos paaiškinamumo koeficientas  $R^2 = 0.8448$  ir vidutinė absoliutinė procentinė paklaida  $MAPE = 6.65\%$ . Šis rezultatas patvirtina, kad pašalinus vietovės kintamuosius vaizdiniai požymiai pradeda didinti prognozės tikslumą. Gylio metrikas ir struktūrinius duomenis apjungianti grupė (H + D) pasiekė  $R^2 = 0.8534$  ir  $MAPE = 6.88\%$ , todėl pasirodė geriau už vien struktūrinius duomenis, bet prasčiau už modelį su kambarių brangumo lygiais (H + L). Galima teigti, kad kambarių brangumo informacija yra informatyvesnė už gylio metrikas, nes ji paaiškina papildomą duomenų dalį, kuri nepersidengia su gylio duomenimis.

Kadangi buvo naudojamas *XGBoost* algoritmas, galima nustatyti svarbiausius požymius kiekvienoje analizuotoje požymių grupėje. Svarbiausi kiekvienos požymių grupės rodikliai pateikti (žr. **26 pav.**), o grafikuose pateiktą rodiklių informaciją galima rasti (žr. **4.4 lentelė**).



26 pav. Aukštos kokybės duomenų rinkinio svarbiausi požymiai

Iš gautų rezultatų matyti, kad derinant struktūrinius ir brangumo lygių požymius (H + L) didžiausią reikšmę NT kainų prognozei turi miegamųjų skaičius (*num\_beds*, 0.3296) ir bendras plotas (*num\_sqft*, 0.2300). Šie požymiai lemia didžiausią prognozės dalį. Taip pat svarbūs statybos metai (*num\_year\_built*, 0.0935), sklypo plotas (*num\_lot\_size*, 0.0697) ir aukštų skaičius (*num\_stories*, 0.0672). Brangumo lygis (*num\_luxury\_top*, 0.0493) suteikia papildomos, tačiau ne itin didelės informacinės vertės.

Apjungiant struktūrinius požymius ir gylio metrikas (H + D) pagrindiniai rodikliai išlieka miegamųjų skaičius (*num\_beds*, 0.3654) ir bendras plotas (*num\_sqft*, 0.1602). Gylio metrikų svarbą rodo tokie rodikliai kaip kiemo pločio ir aukščio santykis (*num\_frontyard\_aspect\_ratio\_wh*, 0.0356) bei vidutinis svtainės gylis (*num\_livingRoom\_mean\_depth*, 0.0243).

Naudojant vien struktūrinius duomenis (H) galime pastebėti, kad dominuoja miegamųjų skaičius (*num\_beds*, 0.4985) ir bendras plotas (*num\_sqft*, 0.2039). Šie požymiai akivaizdžiai nusveria kitų struktūrinių rodiklių, kaip aukštų skaičius (*num\_stories*, 0.0963) ir statybos metai (*num\_year\_built*, 0.0933) svarbą.

Analizuojant visų trijų požymių grupių derinį (H + L + D) miegamųjų skaičius (*num\_beds*, 0.3595) ir bendras plotas (*num\_sqft*, 0.1644) išlieka pagrindiniai, tačiau gylio požymiai, tokie kaip kiemo vidutinis gylis (*num\_frontyard\_mean\_depth*, 0.0329) ir kiemo pločio bei aukščio santykis (*num\_frontyard\_aspect\_ratio\_wh*, 0.0244), įgauna pastebimą reikšmę.

Gylio metrikų (D) analizė rodo, kad svarbiausias yra svetainės erdvės tankis (*num\_livingRoom\_density*, 0.0787), taip pat reikšmingi virtuvės patalpos tūris (*num\_kitchen\_room\_volume*, 0.0454) ir minimalus svetainės gylis (*num\_livingRoom\_min\_depth*, 0.0394). Tai patvirtina, kad erdvės geometrinės savybės tiesiogiai veikia NT kainų suvokimą.

Modelyje, kuriame naudojami vien brangumo lygiai (L), didžiausią įtaką turi bendras aukščiausio brangumo kambarių skaičius (*luxury\_top*, 0.7141), kuris gerokai pranoksta kitus rodiklius. Mažesnę reikšmę turi atskirų brangumo lygių kambarių skaičius, kaip pigūs kambariai (*0\_count*, 0.0781), brangiausios klasės kambariai (*3\_count*, 0.0769), vidutinio brangumo kambariai (*1\_count*, 0.0719) bei aukšto brangumo kambariai (*2\_count*, 0.0589). Pagal gautus rezultatus galima daryti išvadą, kad būsto kainos prognozei svarbiausias yra dažniausiai pasikartojantis brangumo lygis.

Gylio ir brangumo lygių požymių derinyje (D + L) svarbiausi tampa erdviniai rodikliai, tokie kaip svetainės tankis (*num\_livingRoom\_density*, 0.0870) ir kiemo aukščio bei gylio santykis (*num\_frontyard\_aspect\_ratio\_hd*, 0.0847). Sklypo plotas (*num\_lot\_size*, 0.0147) didelės reikšmės nesudaro.

Apibendrinant, buvo parodyta, kaip NT kainų prognozės tikslumą veikia skirtingos požymių grupės ir duomenų kokybė. Pradėjus nuo visų turimų struktūrinių ir vizualinių duomenų, paaiškėjo, kad aukščiausią rezultatyvumą ( $R^2 = 0.9572$ ;  $MAPE \approx 3.5\%$ ) užtikrina vien struktūriniai požymiai. Galime teigti, kad apribojus duomenų rinkinį iki kokybiškų skelbimų ir pašalinus vietovės koordinates, vizualūs rodikliai, kaip kambarių brangumo lygiai, tapo reikšmingesni, nes požymių grupė (H + L) pasiekė  $R^2 = 0.8703$  ir  $MAPE \approx 6.7\%$ . Gylio metrikos vienos pačios tebėra vidutinio naudingumo, tačiau jos papildomai praturtina prognozę, kai kombinuojamos su struktūriniais duomenimis. Kintamųjų svarbos analizė atskleidė, kad miegamųjų skaičius ir bendras plotas išlieka svarbiausi beveik visose kombinacijose, o vizualūs požymiai padeda smulkiau koreguoti vertę, kai trūksta kontekstinių vietos duomenų.

#### 4. Nekilnojamojo turto kainų prognozavimo rezultatų apžvalga

Šiame skyriuje pateikiama visų atliktų eksperimentų rezultatų apžvalga ir tarpusavio palyginimas. Pirmasis etapas buvo skirtas kambarių tipo klasifikavimui. Geriausias kambarių klasifikavimo modelis pateiktas (žr. **4.1 lentelė**).

**4.1 lentelė.** Geriausias kambarių klasifikavimo modelis

Modelis	Architektūra	Žingsnis	Mak. epochų sk.	Prec, %	Acc, %	F1-score, %	Recall, %	Laikas, s
Vision Transformers (ViT)	vit_base_patch16_224	0.00001	20	97.9831	97.9522	97.9425	97.9522	403.274644

Kambarių tipo klasifikavimo tikslumas buvo pakankamai aukštas 97.95 %. Tai patvirtina, kad pasirinkta *ViT* architektūra leidžia atpažinti požymius tarp skirtingų kambarių tipų ir atitinkamai juos suklasifikuoti.

Antrasis tyrimo etapas buvo kambarių brangumo lygių klasifikacija. Geriausias brangumo lygių klasifikavimo modelis pateiktas (žr. **4.2 lentelė**).

**4.2 lentelė.** Geriausias brangumo lygių klasifikavimo modelis

Modelis	Architektūra	Žingsnis	Mak. epochų sk.	Prec, %	Acc, %	F1-score, %	Recall, %	Laikas, s
ResNet	resnet34	0.0002	10	40.8897	41.5750	41.1163	41.5750	813.77

Iš rezultatų galime pastebėti, kad kambarių brangumo klasifikavimas yra žymiai sudėtingesnis. Pasiiektas tikslumas yra santykinai žemas 41.58 %. Galime padaryti išvadą, kad kambarių brangumo vertinimas yra subjektyvus ir sudėtingai įgyvendinamas be papildomų paruošimų. Tai irgi yra patvirtinama maišos matricomis, kuriose buvo pastebėtas akivaizdus gretimų klasių maišymas. Visgi galime teigti, kad modelis leidžia gauti naudingos papildomos informacijos NT kainų vertinimui, nes galime įvertinti link kurios brangumo pusės nuotrauka yra artimesnė.

Trečiajame etape buvo apjungti struktūriniai ir vaizdiniai požymiai siekiant atlikti NT kainų prognozę. Apibendrinti rezultatai pateikiami (žr. **4.3 lentelė**).

**4.3 lentelė.** Apibendrinti kokybiškų duomenų struktūriniai ir vaizdinių požymių rezultatai

Tipas	Maksimalus medžio gylis	Mokymosi žingsnis	Medžių skaičius	Minimalus mazgo svoris	Gamma	MSE	MAE	RMSE	MAPE, %	R <sup>2</sup>
H+L+D	9	0.218029	129	9	1.952785	4 853 281 038.6982	29 786.7407	69 665.4939	6.78	0.8643
H	8	0.1422754	216	8	2.314704	5 552 626 575.4748	29 651.1372	74 515.9485	6.65	0.8448
H+D	8	0.049454	465	7	2.822179	5 246 118 138.7933	31 163.2758	72 430.0914	6.88	0.8534
H+L	5	0.170400	370	2	2.633368	4 638 898 383.1612	28 763.5472	68 109.4588	6.74	0.8703
L	10	0.018841	151	3	3.938829	22 383 567 956.1132	105 465.6798	149 611.3898	29.94	0.3743
D	5	0.098744	463	7	3.852109	9 825 998 917.6661	45 296.0243	99 126.1768	10.11	0.7253
D+L	4	0.053617	462	8	2.603149	9 809 925 200.1823	52 427.4827	99 045.0665	12.80	0.7258

Geriausi nekilnojamojo turto kainų prognozavimo rezultatai buvo pasiekti derinant struktūrinius ir vaizdinius duomenis. Struktūriniai duomenys (H) išlieka svarbiausi, pasižymėdami aukštu prognozavimo tikslumu ( $R^2 = 0.8448$ ;  $RMSE = 74\,515.95$ ;  $MAPE = 6.65\%$ ). Įtraukus papildomus vaizdinius požymius, tokius kaip kambarių brangumo lygiai (L) ir erdvinės gylio metrikos (D), pastebėtas reikšmingas modelio tikslumo pagerėjimas. Geriausi rezultatai gauti naudojant požymių grupę (H + L), kur pasiektas aukščiausias modelio tikslumas ( $R^2 = 0.8703$ ;  $RMSE = 68\,109.46$ ;  $MAPE = 6.74\%$ ). Gylio metrikos (D), nors ir suteikė papildomos vertės, atskirai naudojamos parodė mažesnę efektyvumą ( $R^2 = 0.7253$ ;  $RMSE = 99\,126.18$ ;  $MAPE = 10.11\%$ ).

Derinant visus vaizdinius požymius, t. y. brangumo lygius (L) ir gylio metrikas (D) su struktūriniais duomenimis, bendras paklaidos rodiklis sumažėjo  $RMSE = 4850.46$  (nuo 74 515.95 iki 69 665.49). Pašalinus brangumo lygius ir palikus tik (H + D), rezultatai buvo kiek prastesni ( $R^2 = 0.8534$ ;  $RMSE = 72\,430.09$ ;  $MAPE = 6.88\%$ ), kas patvirtina brangumo požymių papildomą vertę bendrame modelyje.

Visgi geriausias bendras rezultatas pasiektas su (H + L) požymiu grupe, kai užfiksuotas aukščiausias  $R^2 = 0.8703$  bei mažiausias  $RMSE = 68\,109.46$ . Modelis, paremtas vien struktūriniais požymiais (H), nusileido aukščiau minėtoms požymiu grupėms ( $R^2 = 0.8448$  ir  $MAPE = 6.65\%$ ), patvirtindamas, kad pašalinus vietovės kintamuosius vaizdiniai požymiai pradeda didinti prognozės tikslumą. Požymių grupė (H + D) pasirodė geriau ( $R^2 = 0.8534$ ;  $MAPE = 6.88\%$ ) už vien struktūrinius duomenis, tačiau prasčiau už (H + L) požymių grupę, todėl galima teigti, kad kambarių brangumo informacija yra informatyvesnė už gylį.

Atlikus modelių palyginimą ir įvertinus jų stipriąsias bei silpnąsias puses, galima išskirti keletą pagrindinių išvadų. Apibendrinant visų eksperimentų rezultatus, galima teigti:

- Struktūriniai požymiai (H) išlieka svarbiausiais rodikliais nekilnojamojo turto kainų prognozavime;
- Vaizdiniai požymiai, įskaitant erdvinės gylio metrikas ir brangumo lygius, turi reikšmingos papildomos informacijos, kuri pagerina modelio tikslumą;
- Erdvinė informacija gylio metrikos turi didesnę vertę negu estetinio pobūdžio brangumo lygių rodikliai;
- Kambarių tipo klasifikavimo modelis parodė aukštą tikslumą ir gali būti patikimai pritaikomas praktinėse nekilnojamojo turto vertinimo užduotyse;
- Kambarių brangumo vertinimas išlieka problematiškas, tačiau neviseiškai tikslus rezultatai gali būti naudingi kaip papildomi rodikliai bendroje kainų prognozėje.

Galime daryti išvadą, kad panašiuose tyrimuose rekomenduojama naudoti tik aukštos kokybės vaizdinius duomenis, kurie padėtų užtikrinti tikslesnį nekilnojamojo turto kainų vertinimą. Žemesnės kokybės vaizdiniai duomenys gali ne tik nepagerinti, bet ir apsunkinti struktūriniais požymiais paremtų modelių optimizavimą, kadangi vaizdinės ir struktūrinės informacijos požymiai didina kintamųjų paieškos erdvę (*angl. „Curse of Dimensionality“*). Taip pat, verta pastebėti, kad vaizdiniai požymiai gali paaiškinti mažiau informacijos apie NT objektą nei skelbimo struktūrinė informacija, todėl tokio tipo požymiai ne visada leis sudaryti geresnį prognozavimo modelį.

## Išvados

Atliktas tyrimas patvirtino, kad dirbtinio intelekto metodų taikymas gali pagerinti nekilnojamojo turto kainų prognozavimo tikslumą. Darbe iškelti uždaviniai buvo sėkmingai įgyvendinti, o atliktų eksperimentų rezultatai leidžia teigti:

1. NT duomenų rinkinys buvo sudarytas iš 8200 skelbimų iš Hiustono ir aplinkinių vietovių. Išanalizavus ir pagerinus duomenų kokybę, galutiniams eksperimentams buvo atrinkti 1616 aukštos kokybės skelbimai. Tai leido užtikrinti objektyvesnius rezultatus vertinant bei išryškinti vaizdinių duomenų įtaką.
2. Iš NT skelbimų nuotraukų sėkmingai buvo išgauti vaizdiniai požymiai:
  - 2.1. Kambarių tipų klasifikacija pasiekė aukštą 97.98 % tikslumą naudojant *Vision Transformer (ViT)* modelio *vit\_base\_patch16\_224* architektūrą. Tai leidžia teigti, kad kambarių tipai pasižymi aiškiais vizualiniais požymiais, kuriuos galima gerai identifikuoti.
  - 2.2. Kambarių brangumo lygių klasifikacija pasiekė žemesnę, tačiau prasmingą 41.58 % tikslumą naudojant *ResNet34* architektūrą. Iš gautų rezultatų buvo galima pastebėti, kad šis vertinimas yra sudėtingesnis dėl subjektyvaus brangumo suvokimo.
3. Mašininio mokymosi modelių tikslumo analizė buvo atlikta naudojant struktūrizuotus ir vaizdinius duomenis. Naudotas *XGBoost* algoritmas pasiekė pakankamai gerus rezultatus:
  - 3.1. Aukščiausias NT kainų prognozavimo tikslumas buvo gautas naudojant tik struktūrinius pradinius duomenis ( $R^2 = 0.9572$ ), o tai rodo, kad struktūrinė informacija, tokia kaip kambarių skaičius, plotas ar statybos metai, yra esminė ir patikimiausia prognozuojant nekilnojamojo turto kainas.
  - 3.2. Pašalinus lokacijos informaciją ir derinant struktūrinius duomenis (H) su vaizdiniais brangumo lygių (L) ir gylio (D) požymiais, prognozavimo tikslumas išliko aukštas ( $R^2 = 0.8643$ ; MAPE = 6.78 %). Lyginant su tik struktūriniais duomenimis ( $R^2 = 0.8448$ ; MAPE = 6.65 %), papildomi vaizdiniai duomenys šiek tiek sumažino santykinę paklaidą, nors bendras  $R^2$  rodiklis išliko aukštesnis nei vien struktūrinio duomenų modelio.
  - 3.3. Modelyje naudojant tik struktūrinius duomenis ir brangumo lygius (H + L), buvo pasiektas geriausias bendras rezultatas, turint aukščiausią  $R^2 = 0.8703$  ir santykinai žemą vidutinę absoliučią procentinę paklaidą MAPE = 6.74 %. Šis rezultatas patvirtina, kad brangumo lygių klasifikacija (L), nors pati savaime yra sudėtinga ir tikslumu ribota, yra pakankamai naudinga, kai yra naudojama kartu su struktūriniais duomenimis.
  - 3.4. Derinant visus turimus požymius (H + D + L), buvo gauti kiek prastesni rezultatai nei naudojant tik (H + L) požymių grupę ( $R^2 = 0.8643$ ; MAPE = 6.78 %). Tai rodo, kad papildomas gylio matavimų požymių įtraukimas nepadidino bendro modelio tikslumo.
  - 3.5. Vien gylio informacija (D) buvo naudinga, tačiau pastebimai mažiau efektyvi nei kiti deriniai ( $R^2 = 0.7253$ ; MAPE = 10.11 %). Šis rezultatas leidžia teigti, kad erdviniai gylio požymiai, nors ir suteikia vertingos informacijos apie kambario struktūrą, negali savarankiškai užtikrinti aukšto NT kainų prognozavimo tikslumo.
  - 3.6. Tik brangumo lygių požymių (L) naudojimas pasirodė esantis prasčiausias iš visų variantų, žymiai atsiliekant nuo kitų modelių ( $R^2 = 0.3743$ ; MAPE = 29.94 %). Šis pastebėjimas dar kartą patvirtina brangumo lygių subjektyvumą ir ribotą savarankišką pritaikymą.
  - 3.7. Įdomu pastebėti, kad derinant gylio ir brangumo lygių požymius be struktūrinių duomenų požymių grupę (D + L), pasiektas santykinai geresnis rezultatas nei naudojant šiuos požymius atskirai ( $R^2 = 0.7258$ ; MAPE = 12.80 %), tačiau bendras tikslumas vis tiek liko vidutinis.
4. Struktūrinių duomenų modelis buvo patikslintas įtraukiant vaizdinę skelbimų informaciją. Eksperimentai parodė, kad vaizdiniai duomenys gali pagerinti prognozavimo rezultatus, kai struktūriniai duomenys nėra pilni arba juose trūksta reikšmingų NT kainą lemiančių požymių. Buvo pastebėta, kad erdvinės gylio metrikos buvo vertingesnės nei subjektyvūs brangumo vertinimai, tačiau brangumo lygiai leido sudaryti geriausią NT kainos prognozavimo modelį, kai buvo kombinuojami su struktūriniais duomenimis.

5. Sukurta modelių asamblėja, integruojanti kambarių tipo klasifikaciją, brangumo lygių vertinimą ir gylio požymių generavimą, leidžia apdoroti įvairiapusę NT skelbimų informaciją ir atlikti kainų prognozavimą.
6. Identifikuoti ir išanalizuoti reikšmingiausi rodikliai NT kainų prognozei. Struktūriniai požymiai, ypač miegamųjų skaičius ir bendras plotas, išliko svarbiausi tarp skirtingų sudaromų modelių. Gylio metrikos, tokios kaip erdvės tankis ir matmenų santykiai, taip pat reikšmingai prisidėjo prie kainų prognozavimo.

Apibendrinant, sukurtas metodas yra tinkamas praktiniam taikymui NT kainų vertinime. Tyrimo rezultatai patvirtina, kad struktūriniai duomenys išlieka pagrindiniais NT kainų prognozavimo šaltiniais dėl aukšto prognozavimo tikslumo. Vis dėlto vaizdinė informacija, nors ir neduoda ryškaus patikslinimo visais atvejais, yra naudinga kaip papildomas informacijos šaltinis, kai struktūriniai duomenys yra neišsamūs. Šis tyrimas parodė, kad tinkamai panaudojant vaizdinius duomenis, galima pagerinti bendrą kainų prognozių tikslumą ir atlikti patikslinimą. Konkretus eksperimentas, naudojant struktūrinių duomenų ir kambarių brangumo lygių (H + L) derinį, parodė aiškų pagerėjimą lyginant su vien struktūriniais duomenimis ( $R^2$  padidėjo nuo 0.8448 iki 0.8703, RMSE sumažėjo nuo 74 515.95 iki 68 109.46). Tai leidžia suprasti, kad vaizdinė informacija tampa ypač reikšminga, kai struktūriniai duomenys apie nekilnojamąjį turtą yra riboti arba nežinomi.

## Literatūros sąrašas

1. CHAMBERS, David; SPAENJERS, Christophe; STEINER, Eva. *The rate of return on real estate: long-run micro-level evidence* [interaktyvus]. 2021 [mokslo darbų rankraštis]. [žiūrėta 2025-01-04]. Prieiga per: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3407236](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3407236)
2. LIU, Jie. *Artificial intelligence in the 21st century* [interaktyvus]. 2018. [žiūrėta 2025-01-04]. Prieiga per: <https://www.researchgate.net/publication/324023933>
3. CHOWDHURY, Mashrur; SADEK, Antoinette W. *Advantages and limitations of artificial intelligence* [interaktyvus]. Washington (D.C.): The National Academies Press, 2012. [žiūrėta 2025-01-05]. Prieiga per: <https://www.researchgate.net/publication/307928959>
4. YAZDANI, Mahdieh. *Machine learning, deep learning, and hedonic methods for real-estate price prediction* [interaktyvus]. arXiv preprint arXiv:2110.07151. 2021. [žiūrėta 2025-01-05]. Prieiga per: <https://arxiv.org/abs/2110.07151>
5. CHOY, Lily H. T.; HO, Wing K. O. *The use of machine learning in real-estate research. Land* [interaktyvus]. 2023, 12 (4), 740 [žiūrėta 2025-01-06]. Prieiga per: <https://www.mdpi.com/2073-445X/12/4/740>
6. GELZINIS, Arūnas; VERIKAS, Algirdas; VAICIUKYNAS, Egidijus; BACAUSKIENE, Marija; MINELGA, Jonas; HÅLLANDER, Mikael; ULOZAS, Vytautas; PADERVINSKIS, Evaldas. *Exploring sustained phonation recorded with acoustic and contact microphones to screen for laryngeal disorders*. In: 2014 IEEE Symposium on Computational Intelligence in Healthcare and e-Health (CICARE). Piscataway: IEEE, 2014, p. 125–132. [žiūrėta 2025-01-06]. Prieiga per: <https://ieeexplore.ieee.org/document/7007844>
7. ČEH, Miha; KILIBARDA, Marko; LISEC, Anka; BAJAT, Branko. *Estimating the performance of random forest versus multiple regression for predicting prices of apartments*. ISPRS International Journal of Geo-Information [interaktyvus]. 2018, 7 (5), 168. [žiūrėta 2025-04-23]. Prieiga per: <https://www.mdpi.com/2220-9964/7/5/168>
8. WANG, Shuilong; ZHAO, Yuxin. *An optimal house-price prediction algorithm: XGBoost*. *Machine Learning Research* [interaktyvus]. 2023, 3 (1), 3. [žiūrėta 2025-04-23]. Prieiga per: <https://www.mdpi.com/2813-2203/3/1/3>
9. FITRIA; PEBRIADI, M.S. *House-price prediction using the random-forest algorithm on the RapidMiner application*. *Formosa Journal of Science and Technology* [interaktyvus]. 2025, 4 (2), 727–738. [žiūrėta 2025-01-12]. Prieiga per: <https://www.researchgate.net/publication/389662322>
10. AKANDE, Olufemi; OWOLABI, Oluwatemi. *House-price prediction using the random-forest machine-learning technique*. *International Journal of Engineering and Information Systems* [interaktyvus]. 2022, 6 (2), 1–10. [žiūrėta 2025-01-13]. Prieiga per: <https://www.researchgate.net/publication/358351395>
11. CHENG, Xiaoyu. *Comparative analysis of linear regression, Gaussian elimination and LU decomposition for CT real-estate purchase decisions*. arXiv [interaktyvus]. 2023. arXiv:2311.13471. [žiūrėta 2025-04-23]. Prieiga per: <https://arxiv.org/abs/2311.13471>
12. XU, Kang; NGUYEN, Hoang. *Predicting housing prices and analysing the real-estate market in Chicago suburbs using machine learning*. arXiv [interaktyvus]. 2022. arXiv:2210.06261. [žiūrėta 2025-04-23]. Prieiga per: <https://arxiv.org/abs/2210.06261>
13. SHARMA, Hemlata; HARSORA, Hitesh; OGUNLEYE, Bayode. *An optimal house-price prediction algorithm: XGBoost*. arXiv [interaktyvus]. 2024. arXiv:2402.04082. [žiūrėta 2025-04-23]. Prieiga per: <https://arxiv.org/abs/2402.04082>
14. VIKTORATOS, Ioannis; TSADIRAS, Alexandros. *Advancing real-estate forecasting: a novel approach using Kolmogorov–Arnold networks*. *Algorithms* [interaktyvus]. 2025, 18 (2), 93. [žiūrėta 2025-04-23]. Prieiga per: <https://www.mdpi.com/1999-4893/18/2/93>
15. MIRBAGHERIJAM, Mohsen. *Housing-price prediction-model selection based on Lorenz and concentration curves: empirical evidence from Tehran*. arXiv [interaktyvus]. 2021. arXiv:2112.06192. [žiūrėta 2025-04-23]. Prieiga per: <https://arxiv.org/abs/2112.06192>

16. *The artificial neural-networks handbook: part 1* [interaktyvus]. DataScienceCentral, [b.d.]. [žiūrėta 2025-04-23]. Prieiga per: <https://www.datasciencecentral.com/the-artificial-neural-networks-handbook-part-1/>
17. HASAN, Md H.; JAHAN, Mst A.; ALI, Md E.; LI, Y.-F.; SELLIS, Timos. *A multi-modal deep-learning-based approach for house-price prediction*. *arXiv* [interaktyvus]. 2024. arXiv:2409.05335. [žiūrėta 2025-04-23]. Prieiga per: <https://arxiv.org/abs/2409.05335>
18. MOSTOFI, Fatemeh; TOĞAN, Vedat; BAŞAĞA, Hasan Basri. *Real-estate price prediction with deep neural network and principal component analysis*. *Organization, Technology and Management in Construction* [interaktyvus]. Zagreb: University of Zagreb, 2022, 14 (1), 2741–2759. [žiūrėta 2025-04-23]. Prieiga per: <https://doi.org/10.2478/otmcj-2022-0016>
19. TIN, Ting Tin; CHEOK, Jia Wei; ONG, Tzi Min; BOO, Zheng Feng; TOO, Chin Xian. *Real-estate price forecasting utilising recurrent neural networks incorporating genetic algorithms*. *International Journal of Innovative Research and Scientific Studies* [interaktyvus]. Dubai: Arab Open University, 2024, 7 (3), 1216–1226. [žiūrėta 2025-04-23]. Prieiga per: <https://doi.org/10.53894/ijirss.v7i3.3220>
20. ALADSANI, Mohammad; BURTON, Hugh; ABDULLAH, Saud A.; WALLACE, James W. *Machine-learning-driven drift-capacity model for reinforced-concrete walls*. In: *18th World Conference on Earthquake Engineering (WCEE 2024), Milan: International Association for Earthquake Engineering, 2024* [interaktyvus]. [žiūrėta 2025-04-23]. Prieiga per: <https://www.researchgate.net/publication/356192786>
21. ZHANG, Yuwei; HAGHANI, Abdollah. *A gradient-boosting method to improve travel-time prediction*. *Transportation Research Part C: Emerging Technologies* [interaktyvus]. Oxford: Elsevier, 2015, 58, 308–324. [žiūrėta 2025-04-23]. Prieiga per: <https://www.sciencedirect.com/science/article/abs/pii/S0968090X15000741>
22. CHEN, Tianqi; GUESTRIN, Carlos. *XGBoost: a scalable tree-boosting system*. *arXiv* [interaktyvus]. 2016. arXiv:1603.02754. [žiūrėta 2025-04-23]. Prieiga per: <https://arxiv.org/abs/1603.02754>
23. BENTÉJAC, Cédric; CSÖRGŐ, András; MARTÍNEZ-MUÑOZ, Gonzalo. *A comparative analysis of gradient-boosting algorithms*. *Artificial Intelligence Review* [interaktyvus]. 2021, 54, 1937–1967. [žiūrėta 2025-04-23]. Prieiga per: <https://arxiv.org/abs/1911.09070>
24. PROKHORENKOVA, Liudmila; GUSEV, Gleb; VOROBEV, Aleksandr; DOROGUSH, Anna V.; GULIN, Andrey. *CatBoost: unbiased boosting with categorical features*. In: *Advances in Neural Information Processing Systems* [interaktyvus]. 2018, 31. [žiūrėta 2025-04-23]. Prieiga per: <https://arxiv.org/abs/1706.09516>
25. MA, Hao; LI, Shang; AN, Zhaohui. *A fault-diagnosis approach for rolling bearings based on convolutional neural networks and nuisance-attribute projection under various speed conditions*. *Applied Sciences* [interaktyvus]. 2019, 9 (8), 1603. [žiūrėta 2025-04-23]. Prieiga per: <https://www.mdpi.com/2076-3417/9/8/1603>
26. SHEN, Hao; LI, Li; ZHU, Hao; LI, Feng. *A pricing model for urban rental housing based on convolutional neural networks and spatial density: a case study of Wuhan*. *ISPRS International Journal of Geo-Information* [interaktyvus]. 2022, 11 (1), 53. [žiūrėta 2025-01-10]. Prieiga per: <https://www.mdpi.com/2220-9964/11/1/53>
27. KUCKLICK, Jan-Philipp; MÜLLER, Oliver. *Location, location, location: satellite-image-based real-estate appraisal*. In: *ECIS 2020 Research Papers* [interaktyvus]. 2020. arXiv:2006.11406. [žiūrėta 2025-01-24]. Prieiga per: <https://arxiv.org/abs/2006.11406>
28. MING, Yunhao; MENG, Xianglong; FAN, Chun. *A review on monocular-depth estimation: algorithms, datasets and evaluation metrics*. *arXiv* [interaktyvus]. 2021. arXiv:2105.08630. [žiūrėta 2025-01-02].

29. EIGEN, David; PUHRSCHE, Christian; FERGUS, Rob. *Depth-map prediction from a single image using a multi-scale deep network*. *arXiv* [interaktyvus]. 2014. arXiv:1406.2283. [žiūrėta 2025-03-15]. Prieiga per: <https://arxiv.org/abs/1406.2283>
30. RANFTL, René; BOCHKOVSKIY, Alexey; KOLTUN, Vladlen. *Vision transformers for dense prediction*. *arXiv* [interaktyvus]. 2021. arXiv:2103.13413. [žiūrėta 2025-03-15]. Prieiga per: <https://arxiv.org/abs/2103.13413>
31. GODARD, Clément; MAC AODHA, Oisín; BROSTOW, Gabriel J. *Digging into self-supervised monocular-depth estimation*. *arXiv* [interaktyvus]. 2019. arXiv:1806.01260. [žiūrėta 2025-04-23]. Prieiga per: <https://arxiv.org/abs/1806.01260>
32. NOURIANI, Amir; LEMKE, Christian. *Vision-based housing-price estimation using interior, exterior and satellite images*. *Intelligent Systems with Applications* [interaktyvus]. 2022, 14, 200021. [žiūrėta 2025-02-13]. Prieiga per: <https://www.sciencedirect.com/science/article/pii/S2667305322000217>
33. POURSAEED, Omid; YOUSEFNEZHAD, Morteza; TABRIZI, Alireza. *Vision-based real-estate price estimation*. *Machine Vision and Applications* [interaktyvus]. 2018, 29, 781–799. [žiūrėta 2025-01-10]. Prieiga per: <https://arxiv.org/abs/1707.05489>
34. AHMED, Karan; MOUSTAFA, Nesma. *House-price estimation from visual and textual features*. *arXiv* [interaktyvus]. 2016. arXiv:1609.08399. [žiūrėta 2025-01-12]. Prieiga per: <https://arxiv.org/abs/1609.08399>
35. KULCHYTSKY, Yuriy Alex. *Point clouds – everything you need to know* [interaktyvus]. 2024-03-14. [žiūrėta 2025-02-18]. Prieiga per: <https://alterpex.com/blog/what-are-point-clouds>
36. TANDEO, Pierre; AILLIOT, Pierre; BOCQUET, Marc; CARRASSI, Alberto; MIYOSHI, Takemasa; PULIDO, Manuel; ZHEN, Yifan. *A review of innovation-based methods to jointly estimate model- and observation-error covariance matrices in ensemble data assimilation*. *arXiv* [interaktyvus]. 2018. arXiv:1807.11221. [žiūrėta 2025-01-12]. Prieiga per: <https://arxiv.org/abs/1807.11221>
37. RAMOS, Alberto. *Automatic differentiation for error analysis of Monte Carlo data*. *arXiv* [interaktyvus]. 2018. arXiv:1809.01289. [žiūrėta 2025-01-12]. Prieiga per: <https://arxiv.org/abs/1809.01289>
38. DOUGLAS, Daniel; MISHRA, Aashwin; RATNER, Daniel; PETERSEN, Felix; TERAOKA, Kazuhiro. *Uncertainty propagation within chained models for machine-learning reconstruction of Neutrino-LAr interactions* [interaktyvus]. *arXiv preprint arXiv:2411.09864*. 2024. [žiūrėta 2025-01-12]. Prieiga per: <https://arxiv.org/abs/2411.09864>
39. BHAVSAR, Aasawari. *REI-Dataset* [interaktyvus]. 2024 [duomenų rinkinys]. Prieiga per: <https://www.kaggle.com/datasets/aasawaribhavsar/rei-dataset>

## Priedai

### 1 priedas. Požymių grupės ir sudedamieji požymiai

<p><b>Struktūriniai požymiai (H) - 9</b></p> <p><b>Grupės:</b></p> <ul style="list-style-type: none"><li>Vieta (latitude, longitude, city)</li><li>Dydis (beds, baths, sqft)</li><li>Nuosavybės detalės (year_built, lot_size, stories)</li></ul> <p><b>Visi požymiai:</b></p> <ul style="list-style-type: none"><li>latitude</li><li>longitude</li><li>city</li><li>beds</li><li>baths</li><li>sqft</li><li>year_built</li><li>lot_size</li><li>stories</li></ul>	<p><b>Prabangumo vertinimo požymiai (L) - 5</b></p> <p><b>Grupės:</b></p> <ul style="list-style-type: none"><li>Prabangumo klasių skaičiavimai (0-3)</li><li>Aukščiausias prabangumo balas</li></ul> <p><b>Visi požymiai:</b></p> <ul style="list-style-type: none"><li>0_count</li><li>1_count</li><li>2_count</li><li>3_count</li><li>luxury_top</li></ul>	<p><b>Gylio informacijos požymiai (D) - 78</b></p> <p>Kiekvienam iš 6 kambarių tipų:</p> <ul style="list-style-type: none"><li>Fiziniai matmenys</li><li>Tūrio skaičiavimas</li><li>Proporcijų santykiai</li><li>Tankio metrikos</li><li>Gylio statistika</li></ul>
--	--	---

27 pav. Apibendrintos požymių grupės

<p><b>Vonios kambarys (13 požymių)</b></p> <ul style="list-style-type: none"><li>bathroom_room_width</li><li>bathroom_room_height</li><li>bathroom_room_depth</li><li>bathroom_room_volume</li><li>bathroom_aspect_ratio_wh</li><li>bathroom_aspect_ratio_wd</li><li>bathroom_aspect_ratio_hd</li><li>bathroom_density</li><li>bathroom_mean_depth</li><li>bathroom_median_depth</li><li>bathroom_std_depth</li><li>bathroom_min_depth</li><li>bathroom_max_depth</li></ul>	<p><b>Virtuvė (13 požymių)</b></p> <ul style="list-style-type: none"><li>kitchen_room_width</li><li>kitchen_room_height</li><li>kitchen_room_depth</li><li>kitchen_room_volume</li><li>kitchen_aspect_ratio_wh</li><li>kitchen_aspect_ratio_wd</li><li>kitchen_aspect_ratio_hd</li><li>kitchen_density</li><li>kitchen_mean_depth</li><li>kitchen_median_depth</li><li>kitchen_std_depth</li><li>kitchen_min_depth</li><li>kitchen_max_depth</li></ul>
<p><b>Miegamasis (13 požymių)</b></p> <ul style="list-style-type: none"><li>bedroom_room_width</li><li>bedroom_room_height</li><li>bedroom_room_depth</li><li>bedroom_room_volume</li><li>bedroom_aspect_ratio_wh</li><li>bedroom_aspect_ratio_wd</li><li>bedroom_aspect_ratio_hd</li><li>bedroom_density</li><li>bedroom_mean_depth</li><li>bedroom_median_depth</li><li>bedroom_std_depth</li><li>bedroom_min_depth</li><li>bedroom_max_depth</li></ul>	<p><b>Svetainė (13 požymių)</b></p> <ul style="list-style-type: none"><li>livingRoom_room_width</li><li>livingRoom_room_height</li><li>livingRoom_room_depth</li><li>livingRoom_room_volume</li><li>livingRoom_aspect_ratio_wh</li><li>livingRoom_aspect_ratio_wd</li><li>livingRoom_aspect_ratio_hd</li><li>livingRoom_density</li><li>livingRoom_mean_depth</li><li>livingRoom_median_depth</li><li>livingRoom_std_depth</li><li>livingRoom_min_depth</li><li>livingRoom_max_depth</li></ul>
<p><b>Kiemas (13 požymių)</b></p> <ul style="list-style-type: none"><li>backyard_room_width</li><li>backyard_room_height</li><li>backyard_room_depth</li><li>backyard_room_volume</li><li>backyard_aspect_ratio_wh</li><li>backyard_aspect_ratio_wd</li><li>backyard_aspect_ratio_hd</li><li>backyard_density</li><li>backyard_mean_depth</li><li>backyard_median_depth</li><li>backyard_std_depth</li><li>backyard_min_depth</li><li>backyard_max_depth</li></ul>	<p><b>Priekinis kiemas (13 požymių)</b></p> <ul style="list-style-type: none"><li>frontyard_room_width</li><li>frontyard_room_height</li><li>frontyard_room_depth</li><li>frontyard_room_volume</li><li>frontyard_aspect_ratio_wh</li><li>frontyard_aspect_ratio_wd</li><li>frontyard_aspect_ratio_hd</li><li>frontyard_density</li><li>frontyard_mean_depth</li><li>frontyard_median_depth</li><li>frontyard_std_depth</li><li>frontyard_min_depth</li><li>frontyard_max_depth</li></ul>

28 pav. Apibendrinti gylio požymiai

## 2 priedas. Svarbiausi požymiai

### 4.4 lentelė. Svarbiausi požymiai iš kokybiškų duomenų prognozės

Požymiai	H	HL	HD	HLD	D	DL	L
num_0_count		0.03861					0.078139
num_1_count		0.030851	0.010164				0.076943
num_2_count		0.018708					0.071900
num_3_count		0.025582					0.058869
num_backyard_aspect_ratio_hd					0.028041	0.022615	
num_backyard_aspect_ratio_wh					0.020492	0.015054	
num_backyard_mean_depth						0.020922	
num_backyard_room_volume					0.0374	0.02932	
num_backyard_room_width				0.007844			
num_bathroom_aspect_ratio_hd					0.020989	0.01649	
num_bathroom_room_height					0.019423	0.014437	
num_baths	0.045435	0.046989	0.007143	0.010507			
num_bedroom_min_depth			0.015181	0.01414			
num_bedroom_room_depth			0.015198	0.006277			
num_bedroom_room_height					0.01699		
num_bedroom_std_depth					0.020182		
num_beds	0.498508	0.329567	0.365436	0.359495			
num_frontyard_aspect_ratio_hd			0.02005	0.006512		0.084674	
num_frontyard_aspect_ratio_wd			0.015347	0.018515		0.017733	
num_frontyard_aspect_ratio_wh			0.035583	0.024356			
num_frontyard_mean_depth				0.032948			
num_frontyard_room_depth						0.049223	
num_frontyard_room_height				0.018752			
num_frontyard_room_volume			0.008581	0.014456		0.036126	
num_frontyard_room_width				0.013791		0.018687	
num_kitchen_aspect_ratio_hd					0.018176		
num_kitchen_aspect_ratio_wd			0.011299				
num_kitchen_aspect_ratio_wh					0.01768	0.021255	
num_kitchen_density					0.018837		
num_kitchen_median_depth			0.006641	0.008166			
num_kitchen_min_depth					0.024726	0.018678	
num_kitchen_room_volume					0.045445	0.033159	
num_kitchen_std_depth			0.012741		0.01735	0.014412	
num_livingRoom_aspect_ratio_hd					0.018053		
num_livingRoom_aspect_ratio_wh			0.00817		0.019426		
num_livingRoom_density				0.007571	0.078663	0.086991	
num_livingRoom_max_depth				0.006783			
num_livingRoom_mean_depth			0.024322	0.018738	0.02448		
num_livingRoom_min_depth					0.039371	0.022558	
num_livingRoom_room_width						0.019654	
num_lot_size	0.062621	0.069745	0.034235	0.024734		0.014658	
num_luxury_top		0.04925			0.017264	0.015736	0.714148
num_sqft	0.203861	0.230034	0.16019	0.164356			
num_stories	0.096325	0.067197	0.028131	0.013679			
num_year_built	0.09325	0.093469	0.051997	0.052114	0.018675		