

GIS IR DI TECHNOLOGIJŲ TAIKYMAS AUGMENIJOS IDENTIFIKAVIMUI

Arūnas SIPAVIČIUS, Vytauto Didžiojo universitetas, Žemės ūkio akademija, Inžinerijos fakultetas, el. paštas: arunas.sipavicius@vdu.lt

Daiva TIŠKUTĖ-MEMGAUDIENĖ, Vytauto Didžiojo universitetas, Žemės ūkio akademija, Inžinerijos fakultetas, el. paštas: daiva.tiskute-memgaudiene@vdu.lt

Santrauka

Dirbtinio intelekto (DI) metodu – mašininio ir giluminio mokymosi – integracija į GIS sudarė prielaidas naujai sričiai GeoAI, kurios tikslas yra pagreitinti erdvinį sprendimų priėmimą, sumažinti lauko darbų poreikį, padidinti duomenų apdorojimo tikslumą bei sumažinti kaštus. Todėl tyrimai, orientuoti į pažangių AI modelių taikymą GIS aplinkoje ir jų praktinį pritaikomumą automatizuotiems skaitmeniniams paviršiams sudaryti, yra itin aktualūs tiek mokslo, tiek praktinio įgyvendinimo kontekste.

Urbanizuotose teritorijose reljefas ir objektų struktūra yra sudėtinga ir labai tanki. Dėl to kyla iššūkių tiksliai automatizuotai identifikuoti pastatus, augmeniją ir nustatyti jų realius aukščius.

Miestų želdinių (medžių, krūmų) identifikavimas yra labai svarbus tvaraus miesto planavimo komponentas, kuris siejamas su mikroklimatu, oro kokybe, liūčių vandens reguliavimu, ekosistemų vertinimu. Tradicinės želdinių inventORIZACIJOS yra brangios ir retai atnaujinamos, todėl nuotolinio stebėjimo duomenys ir DI analizė leidžia ženkliai sumažinti matavimų kaštus ir padidinti atnaujinimo periodiškumą.

Straipsnyje nagrinėjamas geoinformacinių sistemų (GIS) ir dirbtinio intelekto (DI) taikymo sinergija augmenijos identifikavimui urbanizuotoje teritorijoje pasitelkiant Lietuvos Respublikos apskričių centrų skaitmeninius erdvinius lazerinio skenavimo taškų duomenimis, ortofotografinius vaizdus.

Tyrimo metu nustatyta, kad taikant GIS ir DI technologijas, augmenijos identifikavimui, medžių lapijos užimamo ploto skirtumas sudarė 0,0249 ha identifikuotų medžių 194 vnt., lapijos užimamo ploto 0,486 ha. Identifikuota augmenija sudarė 17,6 proc. visos nagrinėjamos teritorijos

Reikšminiai žodžiai: GIS, DI, Text SAM, LIDAR, augmenija.

Įvadas

Medžiai gyvenamoje aplinkoje teikia naudą žmonių sveikatai valydamiesi orą nuo kenksmingų medžiagų ar sulaikant dulkes, kaitriomis dienomis mažina saulės radiacijos poveikį žmogui ir prisideda prie karščio salos mažinimo mieste, praturtina architektūrinę kompoziciją ir įtvirtina ekologinį stabilumą (Lietuvos arboristikos centras, 2024).

Medžių lajos struktūra, tankis ir dydis yra labai svarbios buveinių, būdingų daugeliui nykstančių paukščių ir kitų rūšių gyvūnų, charakteristikoms (Kumar et al., 2020).

Todėl augmenija urbanizuotoje teritorijoje yra svarbus miesto ekosistemų komponentas, turintis reikšmingą poveikį mikroklimatui, oro kokybei ir biologinei įvairovei.

Lietuvoje nėra daug nuotolinių tyrimų želdinių inventORIZACIJAI urbanizuotoms teritorijoms, tai dažniau miškų apskaitos tyrimai, kuriems skiriama daug dėmesio. Labai daug tyrimų fokusuojasi ir į žemės ūkio sferą (Venckauskaitė, 2024). Miestų želdinių (medžių, krūmų) identifikavimas yra labai svarbus tvaraus miesto planavimo komponentas, kuris siejamas su mikroklimatu, oro kokybe, liūčių vandens reguliavimu, ekosistemų vertinimu. Tradicinės želdinių inventORIZACIJOS yra brangios ir retai atnaujinamos, todėl nuotolinio stebėjimo duomenys ir DI analizė leidžia ženkliai sumažinti matavimų kaštus ir padidinti atnaujinimo periodiškumą.

Yra labai daug tyrimų, besiremiančių RGB vaizdais, LiDAR ar multispektriniais vaizdais, tačiau naujausios tendencijos miškininkystėje rodo, kad siekiant geresnių rezultatų tobulinami ne tik vieno, bet ir kelių sensorių naudojimas, pavyzdžiui, RGB vaizdų derinimas su LiDAR, hiperspektriniais ar terminiais duomenimis (Chehreh et al., 2023).

Tradicioniniai želdinių inventORIZACIJOS metodai yra daug laiko ir finansinių resursų reikalaujantys tyrimai, todėl vis dažniau taikomi nuotolinio stebėjimo ir DI sprendimai.

GIS gebėjimas tvarkyti ir analizuoti erdvinis duomenis dažniausiai vertinamas kaip erdvinės analizės savybė, kuri labiausiai išsiskiria iš kitos informacijos, kompiuterinio projektavimo ir žemėlapių kūrimo, sistemų (Manfred et al., 1996). Pagrindinė kiekvienos analizės, modeliavimo dalis yra duomenų inžinerija (Naeem et al., 2021). Duomenų valdymas šiais laikais yra svarbi užduotis, užtikrinanti duomenų tikslumą, patikimumą, prieinamumą ir tinkamą duomenų rinkimo organizavimą. Čia gelbėja per pastaruosius metus ypač išpopuliarėjęs ir vis plačiau imamas taikyti dirbtinis intelektas.

Dirbtinio intelekto (DI) metodu – mašininio ir giluminio mokymosi – integracija į GIS sudarė prielaidas naujai sričiai GeoAI, kurios tikslas yra pagreitinti erdvinį sprendimų priėmimą, sumažinti lauko darbų poreikį, padidinti duomenų apdorojimo tikslumą bei sumažinti kaštus. Todėl tyrimai, orientuoti į pažangių AI modelių taikymą GIS aplinkoje ir jų praktinį pritaikomumą automatizuotiems skaitmeniniams paviršiams sudaryti, yra itin aktualūs tiek mokslo, tiek praktinio įgyvendinimo kontekste.

Sujungus dirbtinio intelekto (AI) galimybes su geografinėmis informacinėmis sistemomis (GIS) gaunama Geografinė dirbtinio intelekto (GeoAI) technologija, kuri supaprastina GIS duomenų apdorojimo ir analizės užduotis, jas automatizuodama (Zhang et al., 2021).

Gilasis mokymasis (*neuroniniai tinklai*) pasižymi puikiu našumu ir gebėjimu automatiškai apdoroti ir interpretuoti sudėtingus, nestruktūrizuotus duomenų šaltinius, tokius kaip daugialaikiai palydoviniai duomenų kubai ar taškų debesys. Šios technologijos klasifikuojant ir segmentuojant 3D duomenų taškus, kaip taškų debesis, leidžia tiksliai atpažinti paviršiaus pokyčius, struktūras ar objektus, būtinus tiksliai žemės paviršiaus skaitmeninio modelio (angl. DTM/DSM) sudarymui (Ahmed Diab et al., 2022).

Pažangiausia GeoAI kryptis yra pagrindiniai modeliai (angl. foundation models), tokie kaip „Segment Anything“, „Presto“ ar „Prithvi-100M“. Jie treniruojami su milžiniškais duomenų kiekiais ir geba atlikti įvairias užduotis su minimaliu papildomu mokymu. Tai leidžia taikyti bendruosius AI modelius geoduomenų srityje daug efektyviau nei tradiciniai, nuo nulio mokomi modeliai, taip sumažinant pritaikymo laiką ir kaštus, kas yra ypač svarbu apdorojant globalius ar regioninius skaitmeninio paviršiaus modelio duomenis (Smolarezyk, 2025).

„Segment Anything Model“ (angl. SAM) gali segmentuoti objektus įvesties vaizduose, remdamasis lengvais įvesties raginimais, tokiais kaip vienas (ar keli) taškai, ribojantis langelis (angl. Mask) (Ren et al., 2024).

Šiame straipsnyje, remiantis praktiniu darbu, taikomas integruotas GIS ir dirbtinio intelekto metodas, leidžiantis automatizuoti paviršiaus modelių kūrimą, panaudojant LIDAR duomenų klasių informaciją (žemės danga, augmenijos aukščių klasės, pastatai) ir naudojant atstumų klasterizavimą identifikuojami taškai, kurie priklauso tam pačiam objektui, grupei. Taip pat panaudojant (angl. Segment Anything) (SAM) DI modelį identifikuojant objektus iš ortofotografinių vaizdų.

Tyrime siekiama įvertinti GIS ir DI modelių naudojimą augmenijos identifikavimui naudojantis Lietuvos Respublikos apskričių centrų skaitmeniniais erdviniais lazerinio skenavimo taškų duomenimis.


Šio tyrimo tikslas – taikant GIS ir DI technologijas identifikuoti urbanistinėje teritorijoje esančią augmeniją.

Iškeltam tikslui pasiekti sprendžiami šie **uždaviniai**:

1. Naudojant LIDAR ir ArcGIS PĮ identifikuoti medžių lapijos užimamą plotus ir identifikuoti medžių aukščius.
2. Panaudojant DI įrankį „TEXT SAM“ identifikuoti ir nustatyti medžių lapijos užimamą plotą ir aukščio pasiskirstymą.
3. Palyginti gautus rezultatus.

Tyrimų objektas ir metodai

Tyrimo objektas yra Panevėžio miesto centrinė dalis, kuri apima Senvagės teritoriją ir gretimas urbanizuotas erdves, patenkančias į Lietuvos koordinatų sistemos LKS-94 tinklelio kvadratą 64/55. Ši teritorija buvo pasirinkta, nes pasižymi dideliu erdvinio objektų tankiu ir ryškia reljefo, žemės dangos bei urbanistinės struktūros įvairove. Tyrimo objektas, pažymėtas 1 paveiksle, apima 25 ha centrinės miesto dalies.



Šaltinis: sudaryta autoriaus
Source: compiled by the author

1 pav. Tyrimo objektas
Fig. 1. Research object

Tyrime naudoti Lietuvos Respublikos apskričių centrų skaitmeniniai erdviniai lazerinio skenavimo taškų duomenys (LiDAR taškų tankis >30 (vid. 45) tšk./kv. m tikslumas: horizontalios padėties nustatymo – RMSE<30 cm, vertikalios – RMSE<10 cm. Taškai yra klasifikuoti į 13 klasių su priskirtomis RGB reikšmėmis) (žr. 1 lentelę).

Atliekant šį tyrimą buvo naudojamosi ESRI Arcgis programine įranga ArcGIS PRO 3.6. su 3D analizės (angl. 3D analyst), rastrų analizės (angl. image analyst), erdvinės analizės (angl. spatial analyst) plėtiniais, dirbtinio intelekto (angl. deep learning) bibliotekomis ir giliojo mokymosi „Text SAM“ atvirojo kodo DI modelis, kuris skirtas objektų identifikavimui, naudojant tekstinę įvestį (Esri, 2026).

Duomenų šaltinis: www.geoportal.lt, <https://livingatlas.arcgis.com/en/home/>

LIDAR – nuotolinio stebėjimo technologija, kuri leidžia didelio tikslumo būdu nustatyti žemės paviršiaus ir virš jo esančių objektų erdvinę padėtį. Sistemos technologija paremta lazerinius impulsus siuntimo ir matuojamo laiko, per kurį signalas atsispindi nuo objekto ir grįžta į sensorių, principu.

LiDAR plačiai taikoma skaitmeninių reljefo DTM (angl. Digital Terrain Model), paviršiaus DSM (angl. Digital Surface Model) ir aukščių DEM (angl. Digital Elevation Model) modelių sudarymui.

Tyrimo darbo eiga suskirstyta į šiuos etapus:

- Lidar duomenų taškų filtravimas ir skaitmeninių DTM, DTM modelių sudarymas;
- DEM Aukščių modelio sudarymas;
- RGB Ortofotografinio vaizdo sudarymas;
- augmenijos objektų išskyrimas iš LIDAR taškų debesies (angl. Point Cloud);
- augmenijos identifikavimas iš RGB Ortofotografinio vaizdo naudojant DI „Text SAM“ modelį;
- aukščių pasiskirstymas identifikuotiems augmenijos objektams.

1 lentelė. LIDAR duomenų klasifikavimas

Table. 1. LIDAR data classification

Klasės kodas	Klasės pavadinimas	Aprašymas
0	Created, Never Classified	Sisteminiai arba automatiškai sukurti, bet neklasifikuoti taškai
1	Unclassified	Nepriskirti jokiai konkrečiai klasei taškai
2	Ground	Žemės paviršiaus taškai, naudojami DTM sudarymui
3	Low Vegetation	Žema augmenija (žolė, krūmai iki ~0,5 m)
4	Medium Vegetation	Vidutinė augmenija (~0,5–2 m)
5	High Vegetation	Aukšta augmenija (>2 m, medžiai)
6	Building	Pastatų ir statinių paviršiai
7	Low Point (Noise)	Klaidingi žemi taškai (triukšmas)
8	Model Key-Point	Rankiniu būdu pažymėti svarbūs modelio taškai
9	Water	Vandens telkinių paviršiai
10	Rail	Geležinkelio objektai
11	Road Surface	Kelių ir gatvių paviršiai
12	Overlap Points	Persidengiančių skrydžių zonų taškai
13–15	Reserved	Rezervuotos klasės
17	Bridge Deck	Tiltų važiuojamosios dalys
18	High Noise	Aukšti triukšmo taškai

Šaltinis: sudaryta autoriaus

Source: compiled by the author

Sudarant skaitmeninius žemės paviršiaus DTM ir paviršiaus DSM modelius, Arcgis Pro aplinkoje, buvo naudojami (angl. Make LAS dataset layer) ir (angl. LAS Dataset to Raster) įrankiai.

Reikia atkreipti dėmesį į tai, kad skirtingiems modeliams sudaryti buvo naudoti skirtingi įrankių parametrai: DTM atveju įrankiu (angl. Make LAS dataset layer) buvo filtruojami 2 klasės, žemės paviršiaus taškai, tuo tarpu DSM pasirenkami visų klasių taškai su pirmąja grąža (angl. first return) (Esri Support, 2023).

Skirtingiems LAS duomenų rinkiniams skiriasi ir „LAS Dataset to Raster“ įrankio konfigūracija. Generuojant skaitmeninį reljefo modelį (DTM), pasirenkamas ląstelių priskyrimo tipas yra „AVERAGE“, tuo tarpu paviršiui (DSM) – „MAXIMUM“. Abiem skaitmeniniams modeliams naudojamas „NATURAL_NEIGHBOR“ tuštumos užpildymo metodas. Generuojant skaitmeninį reljefo modelį labiau tinkamas „AVERAGE“ ląstelių priskyrimo tipas paskutiniosios grąžos taškams, o tuo tarpu „MAXIMUM“ geriausiai panaudojamas kuriant skaitmeninius paviršiaus modelius.

Norint nustatyti medžių lajos aukštį, reikalingas skaitmeninis paviršiaus modelis (DSM) ir skaitmeninis reljefo modelis (DEM). Naudojant įrankį (angl. Raster calculator), kuriame iš skaitmeninio paviršiaus modelio yra atimamas skaitmeninis reljefo modelis. Gaunamas aukščių (DEM) modelis, kuris būtent ir atspindi medžių lajos aukščius.

Iš LIDAR duomenų RGB reikšmių generuojant ortofotografiniam vaizdai naudojamas (angl. LAS Dataset To Raster) įrankis, kur vertės parametras (angl. value field) pasirenkamas RGB (8-bit, 3-band) ląstelės dydis nustatant 0,3 m., pagal DI modelio „Text SAM“ naudojimą. Pasirenkamas ląstelių priskyrimo tipas – „AVERAGE“, tuštumų užpildymo metodas (angl. Void Fill Method), „naturalūs kaimynai“ (angl. Natural Neighbor).

ArcGis Pro aplinkoje naudojant 3D analizės ir duomenų valdymo įrankius: išskiriami objektai iš taškų debesies (angl. Extract Objects From Point Cloud), formuodami dvimatę daugiasluoksnių elementų sritį (angl. Multipatch Footprint) ir šalinant daugiakampių dalis (angl. Eliminate Polygon Part), kurios identifikuotos kaip maža, iki 2 kv. m ploto, reikšmės, atskiriant kelių dalių įvesties elementus į vienos dalies elementų klasę (angl. Multipart To Singlepart).

Taikant duomenų valdymo metodą (angl. feature to point) sukuriamas naujas taškinis medžių elementų sluoksnis, kuriam pritaikius zoninę statistinę analizę (angl. zonal statistics as table), yra apskaičiuojamas taško (medžio) aukštis.

Zoninės statistinės analizės metu yra panaudojamas iš LIDAR duomenų sugeneruotas skaitmeninis aukščio modelis (angl. Digital Elevation Model).

Objektus išskyrimui iš taškų debesies (angl. Extract Objects From Point Cloud) kaip įvestis buvo panaudoti Lietuvos Respublikos apskričių centrų skaitmeninių erdviųjų lazerinio skenavimo LIDAR aukštos augmenijos klasės (angl. 5 – High Vegetation) taškų duomenys, pasirenkant 3D įgaubto korpuso (angl. Concave Hull) objekto išvesties geometrijos tipą su 1 m. klasterio atstumu (angl. clustering distance) tam pačiam objektui identifikuoti vertinant, kad urbanizuotoje miesto teritorijoje augmenijos objektai – medžiai – nebuvo sodinami mažesniu nei 1 m atstumu.

Siekiant nustatyti medžių aukščius iš gautų medžių lapijos daugiakampių (angl. polygon), naudojamas zoninės statistikos įrankis (angl. Zonal Statistics as table) gauti minimalias, vidutines ir maksimalias reikšmes, priskiriant gautų reikšmių lentelę naujam sukurtam taškinių medžių elementų sluoksniui.

DI „Text SAM“ modelis buvo persiųstas iš ArcGIS gyvojo pasaulio atlaso (<https://www.arcgis.com/home/item.html?id=8df3bf4167bc4c7b967f677f8b362ec3>).

Regėjimo kalbos gilaus mokymosi modelis objektams aptikti ir segmentuoti naudojant tekstinę įvestį leidžia vartotojams išskirti elementus iš vaizdų be iš anksto nustatytų klasių. Šis modelis sujungia „GroundingDINO“ ir SAM galimybes atlikti nulinio kadro aptikimą ir segmentavimą tiesiai iš natūralios kalbos įvesties, palaikydamas lanksčią ir išmanią geoprinę analizę.

Tai pasiekama naudojant „Grounding DINO“ ir „Segment Anything Model“ (SAM). „Grounding DINO“ yra atvirojo kodo objektų detektorius, kuris gali rasti objektus pateikus tekstą. „Segment Anything Model“ gali būti naudojamas bet kokiam objektui segmentuoti dominančioje srityje, kurią vaizduoja ribojantis langelis arba taškas. Abu modeliai šiame gilaus mokymosi pakete iškviečiami nuosekliai. Ribojantys langeliai, vaizduojantys aptiktus objektus iš „Grounding DINO“, yra pateikiami į „Segment Anything Model“ kaip rekomendacija objektui generuoti. Galiausiai objektas konvertuojamas į daugiakampius ir grąžinamas kaip GIS elementas. Šie elementai, aprašyti įvesties teksto įvestyje, gali būti bet kokie dominantys objektai, pvz., transporto priemonės, baseinai, laivai, lėktuvai, saulės baterijos, medžiai, automobilis ir t.t.

Prieš naudodami šį modelį, įsitikinama, kad į ArcGIS PRO programinę įrangą yra įdiegtos ir palaikomos gilaus mokymosi (angl. deep learning) bibliotekos. Ortofotografiniams vaizdams taikomi vaizdų įvesties 8 bitų, 3 juostų RGB vaizdų kriterijai. Darbui su DI ArcGIS Pro aplinkoje naudojamas objektų naudojant gilųjį mokymąsi įrankis (angl. Detect object Using Deep learning). Kaip įvestis naudojamas anksčiau sugeneruotas RGB Ortofotografinis vaizdas, modelio apibrėžtis su numatytais argumentais imamas iš DI „Text SAM modelio (ESRI, 2024).

Teksto įvestyje (angl. Text prompt) įrašomas LIDAR 5 klasės kodo pavadinimas (angl. High Vegetation), pasirenkamas tinkamas langelio dydis (angl. padding) – 256, langelio slenkstis (angl. box threshold), kuris nustato patikimumo balą, pagal kurį aptikimai bus įtraukti į rezultatus – 0,2, teksto slenkstis (angl. box threshold, text threshold), kuris nustato aptiktų objektų susiejimo patikimumo balą su pateikto teksto įvestimi – 0,2, grupės dydis (angl. batch size), kur kiekviename modelio išvados etape apdorojamų vaizdo plytelių skaičius – 4. Priklausomai nuo naudojamos vaizdo plokštės atminties, naudojant geoapdorojimo veiksmus, pasirenkamas procesoriaus tipas GPU.



Tyrimų rezultatai ir jų aptarimas

Tyrimo metu buvo analizuojamas DI ir GIS modelių taikymas identifikuojant augmeniją.

ArcGis Pro įrankiais iš Lietuvos Respublikos apskričių centrų skaitmeninių erdviųjų lazerinio skenavimo taškų duomenų buvo sugeneruoti skaitmeninis reljefo DTM (angl. Digital Terrain Model), paviršiaus DSM (angl. Digital Surface Model) ir aukščio DEM (angl. Digital Elevation Model) modeliai su 0,3 m ląstelės dydžiu, 1 – vaizdo juostų skaičiumi ir slankiojančiu 32 bit-pikselių gyliu ir RGB ortofotografinis vaizdas su 0,3 m ląstelės dydžiu, 3 vaizdo juostų skaičiumi su nepažymėtu 8 bit-pikselių gyliu (žr. 2 lentelę).

2 lentelė. DTM, DSM, DEM modeliai ir RGB ortofotografinis vaizdas

Table 2. DTM, DSM, DEM model and RGB orthophotographic image

DTM	DSM	DEM	Ortofotografinis vaizdas
			
Ląstelės dydis – 0,3 Vaizdo juostų skaičius – 1 Pikslio gylis – 32 bit Slankiojantis pikselio tipas	Ląstelės dydis – 0,3 Vaizdo juostų skaičius – 1 Pikslio gylis – 32 bit Slankiojantis pikselio tipas	Ląstelės dydis – 0,3 Vaizdo juostų skaičius – 1 Pikslio gylis – 32 bit Slankiojantis pikselio tipas	Ląstelės dydis – 0,3 Vaizdo juostų skaičius – 3 Pikslio gylis – 8 bit Nepažymėtas pikselio tipas

Šaltinis: sudaryta autoriaus

Source: compiled by the author

Išskiriant objektus iš taškų debesies (angl. Extract Objects From Point Cloud) formuodami dvimatę daugiasluoksnių elementų sritį (angl. Multipatch Footprint) ir šalinant daugiakampių dalis (angl. Eliminate Polygon Part) kurios identifikuotos, kaip mažo, iki 2 kv. m ploto reikšmės, atskiriant kelių dalių įvesties elementus į vienos dalies elementų klasę (angl. Multipart To Singlepart) gauti 438 vnt. objektų, kurie atspindi medžių lapijos dengiamą plotą, kuris užima 7,721 ha nagrinėjamos teritorijos.

Naudojant DI „Text SAM“ modelį, kai augmenijai identifikuoti buvo naudojamas žodis „Aukšta augmenija“ (angl. High Vegetation), buvo identifikuota 244 vnt. objektų, kurių plotas siekė 7,2349 ha. Naudojant žodį „Medžiai“ (angl. Tree) buvo identifikuota 263 vnt. objektų, kurių plotas siekė 5,8624 ha (žr. 3 ir 4 lentelę).

Tyrimo metu nustatyta, kad taikant GIS ir DI modelį augmenijos identifikavimui „Aukšta augmenija“ (angl. High Vegetation), augmeniją sudaro 17,6 proc. visos nagrinėjamos teritorijos. Gautas rezultatas skiriasi tik 0,0249 ha.

3 lentelė. GIS ir DI modelio grafiniai rezultatai

Table 3. Graphical results of GIS and AI model

Aukšta augmenija (High Vegetation)	Medžiai (Tree)	GIS modelis
		

Šaltinis: sudaryta autoriaus

Source: compiled by the author

4 lentelė. GIS ir DI modelio rezultatai

Table 4. “GIS and DI model results

„Text SAM“ DI modelis (Aukšta augmenija)		„Text SAM“ DI modelis (medžiai)		GIS modelis (LIDAR 4–5 klasė)	
Skaičius vnt.	Plotas (ha)	Skaičius vnt.	Plotas (ha)	Skaičius vnt.	Plotas (ha)
244	7,2349	263	5,8624	438	7,721

Šaltinis: sudaryta autoriaus

Source: compiled by the author

Naudojant aukščio DEM (angl. Digital Elevation Model) skaitmeninį modelį ir zoninę statistinę analizę (angl. zonal statistics as table) buvo nustatytos tiriamųjų objektų (plotų) mažiausios, didžiausios ir vidutinės aukščių reikšmės, aukščių pasiskirstymas vienetais ir užimamas plotas (žr. 5 lentelę).

5 pav. Augmenijos pasiskirstymas pagal aukštį

Fig. 5. Vegetation distribution by altitude

Text SAM Aukšta augmenija (High Vegetation)	Kiekis		GIS modelis
	MEAN  1,223619 - 3,022677 3,022678 - 4,842360 4,842361 - 6,738852 6,738853 - 8,933891 8,933892 - 13,095023		
Iki 2.6 m	40 vnt. (1,0555 ha)	189 vnt. (3,8606 ha)	Iki 3 m
2.6–5 m	50 vnt. (2,6442 ha)	96 vnt. (0,8953 ha)	3–5 m
5–7 m	66 vnt. (1,6301 ha)	70 vnt. (0,9534 ha)	5–7 m
7–9 m	48 vnt. (0,7479 ha)	54 vnt. (0,9191 ha)	7–9 m
9–13 m	38 vnt. (1,0987 ha)	29 vnt. (1,0926 ha)	9–13 m

Šaltinis: sudaryta autoriaus

Source: compiled by the author

Analizuojant tyrimo metu gautus duomenis matyti, kad tiriamojoje teritorijoje didžiausią augmenijos dalį užima augmenija iki 3 m aukščio (50 proc.), nuo 3–5 m (11,6 proc.), 5–7 m (12,3 proc.), 7–9 m (11,9 proc.), 9–13 m (14,1 proc.) visos identifikuotos augmenijos.

Išvados

Tyrimo metu, taikant GIS ir DI technologijas Panevėžio miesto centrinės dalies 25 ha plote, kuri apima Senvagės teritoriją ir gretimas urbanizuotas erdves, patenkančias į Lietuvos koordinatų sistemos LKS-94 tinklelio kvadratą 64/55 teritorijoje, buvo identifikuota augmenija, medžių lapijos užimamas plotas, medžių aukštis ir jo pasiskirstymas.

Naudojant Arcgis Pro programinę įrangą sukurti skaitmeniniai reljefo DTM (angl. Digital Terrain Model), paviršiaus DSM (angl. Digital Surface Model) ir aukščių DEM (angl. Digital Elevation Model) modeliai, sugeneruotas RGB ortofotografinis vaizdas.

Taikant GIS ir DI technologijas augmenijos identifikavimui, nustatyta, kad medžių lapijos užimamo ploto skirtumas sudarė 0,0249 ha identifikuotų medžių 194 vnt., lapijos užimamo ploto 0,486 ha.

Teritorijoje identifikuota augmenija sudarė 17,6 proc. visos nagrinėjamos teritorijos. Tyrimo metu identifikuota 438 vnt. medžių, kurių lapijos užimamas plotas sudarė 7,721 ha. Didžiausią augmenijos dalį užima augmenija iki 3 m aukščio (50 proc.), nuo 3–5 m (11,6 proc.), 5–7 m (12,3 proc.), 7–9 m (11,9 proc.), 9–13 m (14,1 proc.) visos identifikuotos augmenijos.

Literatūra

1. Diab, A., Kashef, R., & Shaker, A. (2022). Deep learning for LiDAR point cloud classification in remote sensing. *Sensors*, 22(20), 7868.
2. Esri. (2023). Determine parameters to generate DTM and DSM. <https://doc.arcgis.com/en/imagery/workflows/best-practices/determine-parameters-to-generate-dtm-and-dsm.htm> (žiūrėta 2026-03-20).
3. Esri. (2024). Text SAM: Extracting GIS Features Using Text Prompts. <https://www.esri.com/arcgis-blog/products/arcgis-pro/geoai/text-sam-extracting-gis-features-using-text-prompts> (žiūrėta 2026-03-01).
4. Esri. (2026). Extract Objects From Point Cloud (3D Analyst). Prieiga per internetą: Extract Objects From Point Cloud (3D Analyst). (žiūrėta 2026-03-20).
5. Fischer, M. M., & Scholten, H. J. (1994). *Geographic Information Systems, Spatial Data Analysis and Spatial Modelling: Problems and Possibilities*. Prieiga per internetą: <https://www.taylorfrancis.com/chapters/edit/10.1201/9780203739051-1/geographic-information-systems-spatial-data-analysis-spatial-modelling-introduction-manfred-fischer-henk-scholten-david-unwin> (žiūrėta 2026-02-12).
6. Kumar, J., Weiner, J., Hargrove, W. W., Norman, S. P., Hoffman, F. M., & Newcomb, D. (2015, November). Characterization and classification of vegetation canopy structure and distribution within the Great Smoky Mountains National Park using LiDAR. In *2015 IEEE International Conference on Data Mining Workshop (ICDMW)* (pp. 1478–1485). IEEE.
7. Lietuvos arboristikos centras. (2024). Želdiniai ir jų įtaka aplinkai. <https://www.arboristai.lt/articles/poveikis-zmogui/205-straipsniai22/1160-zeldiniai-ir-j-itaka-aplinkai> (žiūrėta 2026-03-23).
8. Naeem, M., Jamal, T., Diaz-Martinez, J., Butt, S. A., Montesano, N., Tariq, M. I., ... & De-La-Hoz-Valdiris, E. (2021, November). Trends and future perspective challenges in big data. In *Advances in Intelligent Data Analysis and Applications: Proceedings of the Sixth Euro-China Conference on Intelligent Data Analysis and Applications* (pp. 309–325). Springer.
9. Ren, S., Luzi, F., Lahrichi, S., Kassaw, K., Collins, L. M., Bradbury, K., & Malof, J. M. (2023). Segment anything, from space? arXiv. <https://doi.org/10.48550/arXiv.2304.13000> (žiūrėta 2026-02-02).
10. Smolarczyk, T. (2025, July 14). GIS and artificial intelligence: What is GeoAI? Spyrosoft. <https://spyrosoft.com/blog/geospatial/gis-and-artificial-intelligence-what-is-geoai> (žiūrėta 2025-11-22).
11. Venckauskaitė, V. (2024). Medžių inventorizavimo urbanizuotose teritorijose galimybės taikant nuotolinius metodus (Doctoral dissertation, Vilniaus universitetas). <https://epublications.vu.lt/object/elaba:210546537/> (žiūrėta 2026-03-23).
12. Zhang, L., Dong, R., Yuan, S., Li, W., Zheng, J., & Fu, H. (2021). Making low-resolution satellite images reborn: A deep learning approach for super-resolution building extraction. *Remote Sensing*, 13(15), 2872. <https://www.mdpi.com/2072-4292/13/15/2872>

APPLICATION OF GIS AND ARTIFICIAL INTELLIGENCE TECHNOLOGIES FOR VEGETATION IDENTIFICATION

Abstract

The integration of artificial intelligence (AI) methods - machine and deep learning - into GIS has created the prerequisites for a new field of GeoAI, the goal of which is to accelerate spatial decision - making, reduce the need for fieldwork, increase the accuracy of data processing, and reduce costs. Therefore, research focused on the application of

advanced AI models in the GIS environment and their practical applicability for creating automated digital surfaces is extremely relevant both in the context of science and practical implementation.

In urbanized areas, the terrain and structure of objects are complex and very dense. This poses challenges in accurately and automatically identifying buildings, vegetation, and determining their real heights.

Identification of urban greenery (trees, shrubs) is a very important component of sustainable urban planning, which is associated with microclimate, air quality, stormwater regulation, and ecosystem assessment. Traditional greenery inventories are expensive and rarely updated, therefore remote sensing data and AI analysis allow to significantly reduce the costs of measurements and increase the periodicity of updates.

The article examines the synergy of applying geographic information systems (GIS) and artificial intelligence (AI) for vegetation identification in an urbanized area using digital spatial laser scanning point data and orthophotographic images of county centers of the Republic of Lithuania.

During the study, it was determined that when applying GIS and AI technologies for vegetation identification, the difference in the area occupied by tree foliage amounted to 0.0249 ha 194 trees were identified, the area occupied by foliage amounted to 0.486 ha. The identified vegetation constituted 17.6 percent. of the entire territory under study.

Keywords: GIS, AI, Text SAM, LIDAR, vegetation.